

MONIQUE SACARDO FERREIRA

**INFERÊNCIA ESPACIAL DE CLOROFILA A POR REDES NEURAIS
ARTIFICIAIS APLICADAS A IMAGENS MULTIESPECTRAIS E
MEDIDAS TOMADAS *IN SITU***

Presidente Prudente

2011

MONIQUE SACARDO FERREIRA

**INFERÊNCIA ESPACIAL DE CLOROFILA A POR REDES NEURAIS
ARTIFICIAIS APLICADAS A IMAGENS MULTIESPECTRAIS E
MEDIDAS TOMADAS *IN SITU***

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Universidade Estadual Paulista – Campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

Área de Concentração: Aquisição, Análise e Representação de Informações Espaciais.

Orientadora: Profa. Dra. Maria de Lourdes Bueno Trindade Galo

Presidente Prudente

2011

F442i Ferreira, Monique Sacardo.
Inferência espacial de clorofila a por Redes Neurais Artificiais aplicadas a imagens multiespectrais e medidas tomadas *in situ* / Monique Sacardo Ferreira. - Presidente Prudente : [s.n], 2011 96 f.

Orientador: Maria de Lourdes Bueno Trindade Galo
Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia
Inclui bibliografia

1. Inferência espacial. 2. Clorofila a. 3. Redes neurais artificiais I. Galo, Maria de Lourdes Bueno Trindade. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.

CDD 301.363

BANCA EXAMINADORA



PROFA. DRA. MARIA DE LOURDES BUENO TRINDADE GALO
ORIENTADORA



PROFA. DRA. LUCIANA DE RESENDE LONDE
INSTITUTO INTERAMERICANO PARA PESQUISAS EM MUDANÇAS GLOBAIS (IAI)



PROF. DR. ALUIR PORFIRIO DAL POZ
DEPARTAMENTO DE CARTOGRAFIA /FCT/UNESP



MONIQUE SACARDO FERREIRA

PRESIDENTE PRUDENTE (SP), 29 DE JULHO DE 2011

RESULTADO: APROVADA

*Dedico aos verdadeiros mestres da
minha vida, meus pais: Regina e Dudu.
E aos meus irmãos, Mayara e Lúcio.*

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, por me proporcionar todas as experiências vividas durante o mestrado, por tudo o que tenho e o que sou. Agradeço à Ele por colocar as pessoas certas nos momentos certos durante esses 2 anos e meio, às quais também quero agradecer...

Aos meus pais, por serem minha base, meu porto seguro. Pelo amor, dedicação e apoio incondicional. Aos meus irmãos por serem os primeiros a me proporcionarem a experiência da partilha, da amizade. Agradeço de modo geral e muito especial à toda minha família por sempre acreditar no meu potencial e torcerem por mim.

Agradeço à Prof. Maria de Lourdes pela orientação desde à graduação. Pelas instruções, por dividir seu conhecimento comigo, por sempre ter a reação certa às minhas ações, hora me acalmando, hora me “puxando a orelha”. Agradeço à Professora por me permitir conhecer uma profissional tão competente, ética e comprometida como ela é e, principalmente, por acreditar no meu trabalho e me dar liberdade de expor minhas idéias.

Agradeço aos meus grandes amigos e companheiros de pesquisa Alex Utsumi e Rejane Ennes. Obrigada por me ajudarem nas campanhas de campo, nas análises de clorofila, por discutirem e avaliarem meu trabalho comigo. Obrigada por dividirem seus conhecimentos e me desculpe se em algum momento de nervosismo os magoei. Vocês foram fundamentais nessa pesquisa!

Ao Prof. Maurício Galo por todo o suporte na etapa de preparação dos dados para entrada no JavaNNS e também por me ajudar todas as vezes que a ele recorri.

Aos professores Nilton Imai, Renata Araújo e Cristina Rizk responsáveis pelo Laboratório de Tecnologia em Informação Espacial, pelo suporte na análise de dados limnológicos.

Ao Gabriel Mamoru e à Profa. Dra. Ana Pires por serem sempre solícitos na fase de determinação laboratorial de clorofila *a*.

Ao Prof. Edvaldo Velini e ao Tiago Henrique (Unesp – FCA) por viabilizarem a utilização do fluorômetro de campo e auxiliarem sempre que preciso.

Às profissionais do DAEM, Beatriz e Sônia, por todo o suporte logístico das campanhas de campo, por nos autorizar a execução desse trabalho no reservatório Cascata.

À Lauri e à família dela, por nos ceder gentilmente sua casa durante a campanha de campo para condicionamento das alíquotas de água.

Aos amigos do PPGCC, Marcelo Solfa e Marcelo Gaúcho por me auxiliarem com o levantamento GPS e instalação do simulador, respectivamente. À Thais (LATOGEO) pela paciência e boa vontade sempre que necessitei.

Aos companheiros do “Seminário em Sensoriamento Remoto e Geoprocessamento em Análise e Modelagem Ambiental” pela troca de conhecimento, sugestões e discussões e pelos momentos de descontração e desabafo que dividimos.

Também agradeço aos amigos do PPGCC, em especial aqueles com quem convivi diariamente na sala de permanência: Guilherme, Letícia, Fernanda, Luiz, obrigada pela companhia e pelas várias risadas que demos juntos!

Aos queridos amigos Ana Paula, Mayara, Flávia, Cut, Tati, Rodrigo, Renato e Anderson, pelo companheirismo, pelos momentos em que agüentaram meus desabafos ou minha euforia e pelos momentos de descontração, também importantes para o bom andamento do trabalho. Às minhas sempre amigas Thaine, Iza e Higa, que mesmo de longe me presenteiam com verdadeiras amizades.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos concedida, ao Programa de Pós Graduação em Ciências Cartográficas pela infra-estrutura e financiamento das campanhas de campo e participação em eventos e à Fundação de Estudos e Pesquisas Agrícolas e Florestais (FEPAF) pela aquisição da imagem multiespectral.

Com toda sinceridade e gratidão, muito obrigada!

*Se a tranqüilidade da água permite refletir as coisas,
O que não poderá a tranqüilidade de espírito?*

Chuang Tzu

RESUMO

O conhecimento da distribuição espacial da concentração de componentes da água é de fundamental importância para inferir a respeito dos processos ecológicos que ocorrem num sistema hídrico sendo, entretanto, de difícil obtenção. Dentre as variáveis que merecem atenção no monitoramento de ambientes aquáticos, destaca-se a clorofila *a*, a qual é uma substância presente em algas responsáveis pela fotossíntese, organismos que constituem a base da cadeia alimentar nesses ambientes. Por se tratar de um pigmento fotossintetizante, a clorofila *a* apresenta a propriedade de interagir com a radiação eletromagnética, e dessa interação resultam diferentes processos, identificáveis por meio de sensores remotos. Assim sendo, a presente pesquisa se propôs a desenvolver um método de inferência da concentração de clorofila *a* utilizando Redes Neurais Artificiais (RNA). Utilizou-se como dados de entrada para a inferência combinações de bandas espectrais de uma imagem World View-2 e valores de concentração de clorofila *a* obtidos com um fluorômetro de campo, o qual possibilitou uma amostragem densa na área de estudos. A imagem multiespectral foi corrigida radiometricamente, eliminando efeitos de instrumentação e atmosféricos. Ainda, efetuou-se uma suavização espectral em cada uma das bandas e foi avaliado se esse tratamento na imagem possibilitaria melhores resultados de inferência. Os dados de treinamento e validação da RNA foram cuidadosamente selecionados, para garantir que os mesmos representassem de fato as variações de clorofila *a* medidas *in situ*, e, a partir disso, foram avaliados e definidos a arquitetura de RNA e parâmetros mais adequados para modelar a variável de interesse. Ao final do treinamento, as redes foram aplicadas às imagens, espacializando a concentração de clorofila *a* na área de estudos. Dentre as combinações de bandas selecionadas para inferência, o conjunto de dados que apresentou os melhores resultados foi a combinação das bandas 3 (verde), 5 (vermelho) e 6 (*Vermelho limítrofe*) após a suavização com um filtro média, ressaltando a necessidade do tratamento da imagem multiespectral e ainda da utilização de faixas espectrais de conhecida influência da variável estudada no valor registrado pelo sensor.

Palavras-chave: clorofila *a*, inferência espacial, redes neurais artificiais, imagens World View-2

ABSTRACT

The knowledge of the spatial distribution of water components concentrations is of fundamental importance to infer about the ecological processes that occur in an aquatic system, however, is difficult to obtain it. Among the variables that deserve attention in the monitoring of aquatic environments, cite the chlorophyll *a*, which is a substance of photosynthetic algae, organisms that are the basis of the food chain in these environments. Because it is a photosynthetic pigment, chlorophyll *a* has the property to interact with electromagnetic radiation, and it results in different processes, identifiable through remote sensing. Thus, this research intended to develop a chlorophyll *a* concentration inference method using Artificial Neural Networks (ANN). As input for the inference, it was used combinations of World View-2 spectral bands and chlorophyll *a* concentration values obtained with a field fluorometer, which allowed a dense sampling in the study area. The multispectral imagery was radiometrically corrected, eliminating the instrumentation and atmospheric effects. Still, it was performed a spectral smoothing in each of the spectral bands and evaluated whether this treatment would give better results in the inference. The training and validation datasets of the ANN have been carefully selected to ensure that they in fact represent the variations of chlorophyll *a* measured *in situ*, and from this it has evaluated and defined the ANN architecture and more appropriate parameters to model the variable of interest. At the end of training, the networks were applied to the images, giving the chlorophyll spatial distribution in the study area. Among the combinations of bands selected for inference, the best dataset was the combination of green, red and Red Edge bands after a image smoothing with a mean value filter, stressing the need of multispectral imagery pre-processing and also about the use of spectral bands with known influence of the variable in the signal registered by sensor.

Keywords: chlorophyll *a*, spatial inference, artificial neural network, World View-2 imagery

LISTA DE FIGURAS

Figura 1 - Monitoramento de clorofila nas Unidades de Gerenciamento de Recursos Hídricos de São Paulo.....	17
Figura 3 - Resposta espectral da água pela variação da concentração de material orgânico dissolvido.	22
Figura 4 – Curvas de reflectância com diferentes concentrações de clorofila.	23
Figura 5 – Medidas <i>in situ</i> de reflectância da água com diferentes concentrações de argila e areia.....	24
Figura 6 - Variação da reflectância em água contendo algas e diferentes concentrações de TSS.	25
Figura 7 - Fluxos de radiação detectados por sensores remotos para sistemas aquáticos.	27
Figura 8 - Representação simplificada do metabolismo do ecossistema aquático.	30
Figura 9 - Estrutura química da clorofila a.....	32
Figura 10 - Espectro de absorção da clorofila a.	33
Figura 11 - Espectros de excitação e emissão de fluorescência da clorofila a.	34
Figura 12 - Modelo de um neurônio não linear.....	38
Figura 13 - Funções de ativação mais utilizadas em RNA.....	39
Figura 14 - Estrutura de uma rede neural de múltiplas camadas.....	40
Figura 15 - Número de estudos utilizando RNAs publicados nos quatro principais periódicos de Sensoriamento Remoto.	42
Figura 17 - Localização geográfica do reservatório Cascata.....	46
Figura 19 - Comportamento espectral de água com presença de algas e faixas espectrais imageadas pelo sensor World View-2.....	49
Figura 20 - Configuração do fluorômetro para a detecção de clorofila a.....	51
Figura 21 - Proposta metodológica do trabalho.	56
Figura 22 - Resposta espectral da água do reservatório Cascata.....	59
Figura 23 - Espectros de reflectância originais, derivadas de primeira e segunda ordem.....	62
Figura 24 - Elementos amostrais com determinação laboratorial de clorofila <i>a</i>	65
Figura 25 - Curva de calibração dos dados de campo baseada nas análises laboratoriais.	66
Figura 26 - Visualização do trajeto de coleta de dados fluorométricos.	67
Figura 27 - Perfil espectral de um ponto do reservatório Cascata. Dados originais (a) e corrigidos (b).	70
Figura 28 - Média dos ND (a) e reflectância de superfície (b) registrados pelo sensor World View-2 para a área de estudos.....	73
Figura 30 - Resultado da aplicação das RNAs treinadas às imagens World View-2.....	81
Figura 31 - Concentração de clorofila inferida a partir das bandas 3, 5 e 6 de uma imagem World View-2.....	84

LISTA DE QUADROS

Quadro 1 - Características do sensor World View-2.....	50
Quadro 2 - Combinação dos dados de entrada para o JavaNNS.	75

LISTA DE TABELAS

Tabela 1 - Estatística básica das amostragens fluorimétricas de 2010 e 2011.	68
Tabela 2 - Estatística básica dos atributos espectrais do reservatório Cascata.....	72
Tabela 3 - Estatística descritiva dos conjuntos de treinamento e validação.....	76
Tabela 4 - Configuração e resultados das inferências por RNA.	79
Tabela 5 - Estatística descritiva das representações geradas.....	83

SUMÁRIO

1. INTRODUÇÃO	13
1.1. OBJETIVO	15
1.2. JUSTIFICATIVA	16
1.3. ORGANIZAÇÃO DO DOCUMENTO	18
2. FUNDAMENTAÇÃO TEÓRICA	20
2.1. SENSORIAMENTO REMOTO DA ÁGUA	20
2.1.1. COMPORTAMENTO ESPECTRAL DA ÁGUA	20
2.1.2. SENSORIAMENTO REMOTO MULTIESPECTRAL DE AMBIENTES AQUÁTICOS	25
2.2. PIGMENTOS FITOPLANCTÔNICOS: CLOROFILA A	29
2.2.1. IMPORTÂNCIA ECOLÓGICA E CARACTERÍSTICAS DO FITOPLÂNCTON	29
2.2.2. PROPRIEDADES FÍSICO-QUÍMICAS DA CLOROFILA A	32
2.2.3. MÉTODOS DE QUANTIFICAÇÃO DE CLOROFILA A	35
2.3. INFERÊNCIA ESPACIAL POR REDES NEURAS ARTIFICIAIS	36
2.3.1. REDES NEURAS ARTIFICIAIS	37
2.3.2. UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA INFERÊNCIA EM SENSORIAMENTO REMOTO	42
3. CARACTERIZAÇÃO DA ÁREA DE ESTUDOS	45
3.1. DEFINIÇÃO DA ÁREA DE ESTUDOS	45
3.2. CARACTERIZAÇÃO LIMNOLÓGICA BÁSICA DO RESERVATÓRIO	47
4. ESCOPO GERAL DA INVESTIGAÇÃO	49
4.1. MATERIAL	49
4.1.1. IMAGENS ORBITAIS	49
4.1.2. INSTRUMENTOS DE MEDIÇÕES IN SITU	51
4.1.3. SOFTWARES	53
4.2. ABORDAGEM METODOLÓGICA	55
4.3. CARACTERIZAÇÃO ESPECTRAL DO RESERVATÓRIO CASCATA	58
4.4. CONCENTRAÇÃO DE CLOROFILA A POR FLUORIMETRIA DE CAMPO	64
4.5. TRATAMENTO DA IMAGEM MULTIESPECTRAL PARA DETECÇÃO DE CLOROFILA	68
4.6. INFERÊNCIA GEOGRÁFICA DE CLOROFILA A UTILIZANDO REDES NEURAS ARTIFICIAIS	74
5. CONCLUSÕES	85
REFERÊNCIAS BIBLIOGRÁFICAS	88
APÊNDICES	96

1. INTRODUÇÃO

A água é um recurso natural de vital importância ecológica e econômica, da qual depende a sobrevivência de todas as formas de vida no planeta. Embora seja amplamente divulgada a limitação em qualidade e quantidade dos recursos hídricos, os mesmos vêm sendo utilizados, ao longo dos anos, sem adequado planejamento e controle.

As ações produzidas pelas atividades humanas ao explorar os recursos hídricos foram se tornando complexas ao longo da história da humanidade. Tais atividades foram executadas com o intuito de expandir o desenvolvimento econômico e fazer frente às demandas industriais e agrícolas, à expansão e ao crescimento da população das áreas urbanas (TUNDISI, 2003). Assim, o desenvolvimento da sociedade acarretou novas formas de uso dos recursos hídricos, ou seja, os usos múltiplos da água.

O aumento e a diversificação dos usos múltiplos resultaram em uma multiplicidade de impactos de diversas naturezas e magnitudes (TUNDISI, 2003), dentre os quais se cita a eutrofização.

O termo eutrofização designa um processo decorrente do excesso de nutrientes básicos no recurso hídrico, resultado da fertilização excessiva, permanente e contínua de um corpo d'água, acarretando o desenvolvimento massivo e indesejado de algas e macrófitas aquáticas (AZEVEDO NETO, 1988). Devido à diversidade de causas envolvidas nesse processo, as formas de evitá-lo tornam-se complexas. Comumente, procura-se evitar a introdução de nutrientes (principalmente nitrogênio e fósforo), pois o excesso dessas substâncias favorece o crescimento descontrolado de vegetais, podendo tornar-se um problema para utilização da água (BRANCO; BERNARDES, 1983).

Como dito, a eutrofização causa o crescimento excessivo de vegetais no corpo d'água e, o grupo vegetal que responde primeiramente à eutrofização são as algas, ou fitoplâncton. A sensibilidade desses seres à carga de nutrientes decorre do fato de que possuem ciclos de vida menores se comparados às macrófitas aquáticas, portanto, qualquer alteração no corpo d'água é rapidamente assimilada pela comunidade fitoplancônica. Assim, Tundisi (2003) considera que o crescimento excessivo do fitoplâncton está ligado aos primeiros estágios de eutrofização de um ambiente aquático, enquanto que nos estágios avançados há o crescimento indiscriminado de macrófitas aquáticas.



A origem da palavra fitoplâncton é grega, na qual *phyto* significa ‘planta’, e plâncton, proveniente de *plagtos*, ‘vagando’. Esse termo designa um grupo heterogêneo, composto principalmente por algas fotossintetizantes, que se distribui por grande parte dos ambientes marinhos e aquáticos continentais do mundo. Nestes ambientes, é o principal responsável pela captação da energia eletromagnética e sua transformação em energia química - através do processo de fotossíntese - desempenhando, portanto, importante função no sistema. As moléculas que captam e transformam a energia são chamadas de pigmentos fotossintetizantes (ARRAUT et al., 2005).

Segundo Wetzel (2001), a clorofila *a* é o pigmento primário de todos os organismos fotossintetizantes e está presente em todas as classes de algas. Mesmo havendo certa diversidade de pigmentos que absorvem energia solar, é na clorofila *a* que ocorrem as principais reações do processo de fotossíntese. Portanto, como afirmam Martini et al. (2006), a clorofila *a* é o pigmento mais importante na verificação da presença global de organismos fotossintetizantes na água. Os outros tipos de clorofilas e demais pigmentos são úteis como forma de identificar a presença ou dominância de certa classe de algas em uma amostra.

Apesar de fundamental para inferir a respeito dos processos ecológicos que ocorrem num sistema hídrico, medidas representativas da concentração de clorofila *a* são de difícil obtenção. Em muitos casos, a amostragem deve ser de tamanho demasiadamente grande para obtenção de um conjunto de dados adequados para análise do recurso hídrico. Nesse contexto, como cita Londe (2008), o sensoriamento remoto é uma alternativa eficaz de monitoramento da qualidade da água, pois possibilita a realização de estudos em escalas temporais e espaciais adequadas.

Devido à propriedade de interagir com a radiação eletromagnética (REM), provocando diferentes padrões de absorção e espalhamento, a clorofila é considerada um componente opticamente ativo (COA) e, sendo assim, é possível correlacionar sua presença à medidas de reflectância obtidas a partir de bandas espectrais de imagens de sensoriamento remoto.

Ainda, a clorofila é considerada uma substância fluorescente, ou seja, quando irradiada em um comprimento de onda específico (de excitação), o estado eletrônico de sua molécula é alterado e a mesma tende a voltar rapidamente ao estado fundamental por um processo de decaimento energético radiativo em um comprimento de onda geralmente maior que o de excitação.



Nesse sentido, monitorar a fluorescência da clorofila para obter informações do sistema hídrico é uma idéia com virtudes, já que a fluorescência é percebida externamente ao organismo fotossintetizante, podendo ser detectada de maneira não invasiva e não destrutiva; permitindo, assim, o uso de sensores remotos. Barbosa (2003) cita que medidas de fluorescência podem ser realizadas em diferentes escalas, tanto espaciais (de micrômetros a quilômetros) como temporais (de microssegundos a meses). Medidas em tempo-real são particularmente interessantes para entender as respostas fotossintéticas do fitoplâncton uma vez que essas algas não são fixas no espaço.

Com isso, percebe-se que as peculiaridades espectrais da clorofila fornecem diversas maneiras para sua detecção em grande escala em ambientes aquáticos, sendo de responsabilidade da comunidade científica estudar métodos para integração das fontes de dados distintas acerca da variável citada. Se o intuito é o conhecimento do comportamento espacial do pigmento, técnicas de inferência devem ser utilizadas. Dentre tais técnicas, a utilização de Redes Neurais Artificiais (RNAs) é considerada uma alternativa interessante para inferência espacial de variáveis ambientais a partir de dados de sensoriamento remoto.

Desse modo, considerando as interações da clorofila *a* com a radiação eletromagnética incidente, o presente trabalho se pauta no pressuposto de que sensores remotos, tanto espectrorradiométricos quanto fluorimétricos, têm potencial para detectar a presença de clorofila *a* e serem sensíveis à diferentes concentrações da mesma. Assim, a partir de um número considerável de dados de concentração de clorofila (obtidas a partir de técnicas fluorimétricas) e de variáveis que sejam relacionadas à presença da mesma (valores de reflectância registrado por sensores remotos), é possível realizar a inferência geográfica utilizando redes neurais artificiais, possibilitando gerar uma representação da distribuição espacial de clorofila *a*.

1.1. OBJETIVO

O objetivo da presente pesquisa é aplicar uma rede neural artificial treinada a partir de um conjunto de medidas pontuais da concentração de clorofila *a* coletadas em campos e valores de reflectância registrados em uma imagem multiespectral, para realizar o



mapeamento da variável limnológica em questão. Para alcançar tal objetivo, os seguintes objetivos específicos foram delineados:

- Analisar o comportamento espectral da água da área de estudos, identificando as características de absorção e espalhamento da radiação associadas à presença de clorofila *a*;
- Viabilizar uma amostragem densa da concentração de clorofila *a*, por meio de fluorimetria de campo;
- Avaliar o potencial de uma imagem multiespectral de alta resolução espacial na detecção de clorofila *a* no corpo d'água;
- Produzir um mapa da distribuição espacial de clorofila *a* no recurso hídrico.

1.2. JUSTIFICATIVA

O estudo de pigmentos fitoplanctônicos a partir de dados de sensoriamento remoto tem crescido consideravelmente. Isso pode ser constatado ao se observar a crescente publicação de trabalhos relacionados à composição fitoplanctônica, em periódicos de grande impacto da comunidade científica de sensoriamento remoto (BAILEY; WERDELL, 2006; CHEN et al., 2007; GONS et al., 2008; LI et al., 2010; MOORE et al., 2009; NAIR et al., 2008; WERDELL et al., 2009). Quando se trata de sensoriamento remoto orbital, a maioria dos estudos é desenvolvida em águas oceânicas, que contam com um número considerável de sensores adequados à captura de variações na cor do oceano, tais como SeaWiFS (Sea-viewing Wide Field-of-view Sensor), CZCS (Coastal Zone Color Scanner), MODIS (MODerate resolution Imaging Spectroradiometer), dentre outros. Para o estudo de águas interiores, a disponibilidade de sensores é muito menor pois, como cita Bukata (2005) o sensor francês MERIS (*Medium Resolution Imaging Spectroradiometer*) é o único sensor multiespectral desenvolvido para estudos de águas costeiras e interiores. Ainda assim, o MERIS possui uma resolução espacial de 300 m, o que torna, muitas vezes, inviável sua utilização em ambientes aquáticos de pequenas dimensões.



Nesse contexto, investigações a respeito do fitoplâncton de águas interiores, em especial de áreas tropicais, a partir de dados de sensoriamento remoto orbital tem se mostrado um grande desafio, à medida que é necessária a adaptação dos dados disponíveis. Como citam Keiner e Yan (1998), em estudos oceânicos não é difícil desenvolver algoritmos empíricos relacionando grandezas radiométricas com a concentração de clorofila, mas no caso de águas costeiras e interiores essa tarefa é mais complexa devido à presença de sedimentos em suspensão e material orgânico dissolvido, os quais também interferem no sinal registrado pelo sensor.

O trabalho realizado na planície de inundação do Alto Rio Paraná por Ferreira et al. (2009) ilustra as adaptações necessárias aos dados de sensoriamento remoto disponíveis para a espacialização de pigmentos fitoplanctônicos. Os autores utilizaram imagens multiespectrais TM/Landsat e CCD/CBERS-2B na análise de correlação com a variável limnológica pigmentos totais. Embora tenham sido obtidos resultados satisfatórios na correlação e modelagem da distribuição espacial dessa variável, ambientes importantes da planície não foram mapeados devido à incompatibilidade com a resolução espacial desses sensores.

Como mencionado, a clorofila *a* é de fundamental importância para a compreensão do ambiente aquático, e, embora as agências ambientais reconheçam a importância dessa variável, constata-se certa dificuldade na aquisição dessa informação. Observando-se o Relatório de Qualidade das Águas Interiores do Estado de São Paulo - 2008 (CETESB, 2009) percebe-se que apenas 20% das estações monitoradas em todo o estado apresentaram levantamento de clorofila *a*. Essa situação pode ser agravada em algumas regiões do estado, como pode-se observar na Figura 1.




Figura 1 - Monitoramento de clorofila nas Unidades de Gerenciamento de Recursos Hídricos de São Paulo.

Fonte: Adaptado de CETESB (2009).



O Relatório de Qualidade das Águas Interiores do Estado de São Paulo mostra que o número de estações de coleta de variáveis limnológicas é reduzido para todos os ambientes monitorados, reduzindo-se muitas vezes a uma ou duas estações. Trata-se de uma quantidade pequena de pontos, o que pode ser interpretado equivocadamente como o comportamento do ambiente aquático de modo geral. Assim, é necessário incorporar um número maior de medidas que representem as variações no ambiente de interesse.

Entretanto, adensar as medições limnológicas no recurso hídrico traz uma série de complicações operacionais e financeiras. Do ponto de vista operacional, é necessário um planejamento e respectiva coleta de campo, e ainda análises laboratoriais, etapas que demandam equipamentos e pessoal capacitado. Infelizmente, muitas vezes as agências ambientais não possuem quadro de pessoal adequado ou disponível para tais funções.

A situação é agravada no âmbito financeiro, uma vez que análises laboratoriais requerem muitos recursos. Ante o exposto, este trabalho justifica-se por tratar do desenvolvimento de uma metodologia que poderá ser aprimorada e utilizada no gerenciamento ambiental, já que a incorporação de dados de sensores remotos no monitoramento de ambientes aquáticos pode reduzir custos de ordem operacional e financeira para as partes envolvidas.

Nesse sentido, a utilização de dados de sensoriamento remoto pode fornecer uma amostragem densa na área de estudos sem a necessidade de muitas análises laboratoriais, proporcionando uma maior densidade de informações realmente úteis aos gestores de recursos hídricos.

1.3. ORGANIZAÇÃO DO DOCUMENTO

O documento está organizado de forma a contemplar as principais vertentes conceituais e experimentais envolvidas no trabalho, abordando os procedimentos e resultados obtidos durante a realização da pesquisa.

No Capítulo 2 é apresentada a fundamentação teórica a respeito dos três principais focos deste estudo: sensoriamento remoto de ambientes aquáticos, principais características da clorofila *a* e inferência por redes neurais artificiais.



A área de estudos é caracterizada no Capítulo 3 e o Capítulo 4 apresenta os materiais utilizados na pesquisa, a abordagem metodológica utilizada e os procedimentos e resultados obtidos visando contemplar cada um dos objetivos específicos. Assim, no Capítulo 4 é feita a caracterização espectral das águas da área de estudo, o procedimento de coleta de dados fluorimétricos, o tratamento das imagens multiespectrais e o método de inferência espacial.

Finalizando, o Capítulo 5 apresenta as conclusões seguido das referências bibliográficas que nortearam a pesquisa e os apêndices apresentam um detalhamento metodológico de procedimentos efetuados no desenvolvimento do trabalho.



2. FUNDAMENTAÇÃO TEÓRICA

2.1. SENSORIAMENTO REMOTO DA ÁGUA

2.1.1. COMPORTAMENTO ESPECTRAL DA ÁGUA

Ao conduzir uma investigação de sensoriamento remoto de corpos d'água, é primeiramente útil entender como a água pura seletivamente absorve e/ou espalha a radiação incidente ou a luz solar descendente na coluna d'água. Ainda, é relevante considerar como a luz incidente é afetada quando a coluna d'água não é pura, mas contém materiais orgânicos e inorgânicos (JENSEN, 2009).

Existem dois processos que podem acontecer com a radiação na água: absorção e espalhamento. Assim, se o intuito é entender o que acontece à radiação solar que passa em qualquer corpo d'água, é preciso quantificar até que ponto a água absorve e espalha a luz. As propriedades de absorção e espalhamento da água para a luz em qualquer comprimento de onda são especificados em termos de coeficiente de absorção (a), coeficiente de espalhamento (b) e função de espalhamento volumétrico. Estes são chamados por Preisendorfer (1961) de propriedades ópticas inerentes, uma vez que suas magnitudes dependem apenas das substâncias que compõem o meio aquático e não da estrutura geométrica do campo de luz que penetra na água (KIRK, 1994). No caso da água pura, essas propriedades são apresentadas na Figura 2.






Figura 2 - Propriedades ópticas inerentes da água pura: (a) coeficiente de espalhamento, (b) coeficiente de absorção e (c) coeficiente de atenuação difusa.

Fonte: Dekker, 1993.

Observando-se a Figura 2, o espectro de absorção da água pura (b) é mínimo na região compreendida entre 400 e 550 nm, a partir desse ponto aumenta gradativamente até um rápido crescimento na região do infravermelho. Já o coeficiente de espalhamento (a) é máximo na região do azul e decresce exponencialmente na região do infravermelho.

A partir dessas propriedades da água, percebe-se a limitação na utilização de sensoriamento remoto no estudo de sistemas aquáticos. Os estudos são possíveis em uma faixa relativamente estreita do espectro eletromagnético, devido à baixa radiação solar que alcança a superfície terrestre em comprimentos de onda menores de 400 nm e a combinação da baixa energia solar com o abrupto aumento de absorção da energia eletromagnética pela água em comprimentos de onda maiores 850 nm. Desse modo, a faixa espectral entre 400 nm e 850 nm é normalmente escolhida por pesquisadores para o desenvolvimento de métodos para estimativa de parâmetros da qualidade da água por sensoriamento remoto (DEKKER, 1993).

Como afirma Barbosa (2005), a reflectância irradiante de sub-superfície é o resultado dos efeitos combinados e simultâneos de absorção e espalhamento de todos os componentes presentes na coluna d'água, sobre o campo de irradiação incidente. De forma genérica, pode-se dizer que a absorção causará sempre uma redução na reflectância, enquanto que o espalhamento ocasiona um aumento na radiação registrada por um sistema sensor.

Em águas naturais, os componentes opticamente ativos presentes na sub-superfície passam a ser determinantes sobre as propriedades ópticas inerentes de corpos d'água. Material Orgânico Dissolvido (MOD), pigmentos fotossintetizantes e sedimentos em suspensão são as principais substâncias responsáveis pela variação espectral da água. As propriedades de absorção e espalhamento dessas variáveis irão definir seletivamente a forma final da curva de reflectância. Em geral, a variação nas concentrações regulará a intensidade de radiação refletida na sub-superfície e a magnitude das feições espectrais produzidas (KIRK, 1994).

A presença de material orgânico dissolvido na água afeta principalmente os primeiros comprimentos de onda do espectro visível. A influência do MOD no corpo d'água é apresentada na Figura 3, na qual se visualiza curvas espectrais em que a concentração de sólidos suspensos e clorofila *a* são insignificantes e a concentração de Carbono Orgânico Dissolvido (COD), considerado um bom indicador de matéria orgânica dissolvida, se altera no intervalo de 0 a 20 mg C/l. Analisando a figura percebe-se que a adição sistemática de COD resulta em uma diminuição tênue no valor de reflectância nos comprimentos de onda menores que 600 nm (região espectral do azul e verde) e variações pouco significativas nos valores de reflectância em comprimento de onda superiores a 600 nm (BUKATA et al., 1995).




Figura 3 - Resposta espectral da água pela variação da concentração de material orgânico dissolvido.
Fonte: Bukata et al., 1995.

Bukata et al. (1995) citam que o efeito do MOD é mais notável em corpos d'água com predomínio de clorofila que em corpos d'água contendo apenas sólidos em suspensão, e



que a adição de MOD para os dois casos diminui significativamente o valor de reflectância até 600 nm, reforçando a idéia que tal constituinte provoca absorção principalmente em menores comprimentos de onda, mesmo em curvas espectrais resultantes da mistura de componentes opticamente ativos.

De modo geral, os pigmentos que atuam na fotossíntese provocam a diminuição da reflectância nas faixas espectrais do azul (400 - 515 nm) e vermelho (660 - 670 nm) e o aumento na faixa do verde (515 - 600 nm). Rundquist et. al (1996) distinguiram seis feições de absorção e reflexão significativas na resposta espectral a coluna d'água, conforme pode ser observado na Figura 4, na qual é percebida a influência da variação de concentração de clorofila na resposta espectral da água.




Figura 4 – Curvas de reflectância com diferentes concentrações de clorofila.

Fonte: Rundquist et al., 1996.

Como se mostra na Figura 4, a primeira das feições que caracterizam a presença de clorofila na água (feição A) indica baixa reflectância entre 400 e 500 nm devido à absorção da luz azul (com um mínimo em 441 nm). Observa-se, logo em seguida, um pico de reflectância máxima no verde, entre 560 e 570 nm (feição B) e um pequeno ponto de inflexão em torno de 640 nm (feição C), devido ao retroespalhamento causado por pigmentos acessórios ou material orgânico dissolvido. A feição D corresponde a um ponto de absorção no vermelho, em aproximadamente 676 nm, associado ao segundo ponto de absorção máxima por clorofila *a*; a feição E representa um pico bem definido de reflectância no infravermelho próximo, próximo a 700 nm, e finalmente um pico menor (feição F), em aproximadamente



810 nm, provavelmente causado pelo retroespalhamento da matéria orgânica (células algais), combinado com a absorção pela água no infravermelho (RUNDQUIST et al., 1996).

Entre os constituintes de um corpo d'água, os sólidos em suspensão são os componentes opticamente ativos que mais influenciam na resposta espectral das águas. Como afirmam Bukata et. al (1995), minerais como silício, alumínio, óxidos de ferro são encontrados em suspensão na maioria dos corpos d'água. A Figura 5 mostra a variação da resposta espectral da água limpa e da água em função do aumento da concentração de sólidos em suspensão formados por argila e areia.




Figura 5 – Medidas *in situ* de reflectância da água com diferentes concentrações de argila e areia.
Fonte: Jensen, 2009.

Segundo Jensen (2009), os comprimentos de onda entre 580 e 690 nm (visível) fornecem mais informações referentes ao tipo de sedimentos em suspensão no corpo d'água e os comprimentos de onda entre 715 e 880 nm (infravermelho próximo) podem ser usados para estimar a quantidade de minerais suspensos na água. No entanto, essa relação não pode ser universalmente aplicada, pois as concentrações de sedimentos em suspensão se baseiam nas características de absorção e espalhamento da radiação eletromagnética pela água e solos, na região geográfica de interesse.

Ainda, quando há a presença de clorofila e sólidos em suspensão simultaneamente na água, uma resposta espectral diferenciada é produzida. De acordo com Jensen (2009), há um aumento da reflectância ao longo de toda a curva espectral com a elevação da concentração de sólidos (Figura 6).






Figura 6 - Variação da reflectância em água contendo algas e diferentes concentrações de TSS.
Fonte: Han, 1997 apud Jensen, 2009.

Como é ilustrado na Figura 6, para águas que apresentam somente a presença de algas (TSS=0 mg/l) o pico de reflectância se localiza na região do visível correspondente ao comprimento de onda de 550 nm e com a adição de sólidos em suspensão este pico desloca-se gradativamente até 600 nm, tornando-se mais achatado e menos definido. Ainda, verifica-se que existe um aumento gradativo no pico localizado no intervalo de 700 a 720 nm e na região de absorção entre 660 e 670 nm, com o aumento na concentração de sólidos.

Com respeito a essas alterações, Quibell (1991) mostrou que a diferença de reflectância nos comprimentos de onda em cerca de 710 nm e 665 nm ($\rho_{710nm} - \rho_{665nm}$) permanece constante independente da quantidade de sólidos adicionados. Assim, a diferença de reflectância entre essas duas bandas pode fornecer meios de compensação dos efeitos da turbidez em modelos que relacionem radiância e clorofila.

2.1.2. SENSORIAMENTO REMOTO MULTIESPECTRAL DE AMBIENTES AQUÁTICOS

A maioria das pesquisas de sensoriamento remoto é baseada no desenvolvimento de uma relação determinística entre a quantidade de energia eletromagnética refletida, emitida, ou retroespalhada em bandas ou frequências específicas e as características químicas, biológicas e físicas dos fenômenos em investigação. Nesse contexto, define-se como



resolução espectral o número e a dimensão (tamanho) de intervalos de comprimentos de onda específicos (bandas) no espectro eletromagnético aos quais um instrumento de sensoriamento remoto é sensível (JENSEN, 2009).

Sensores multiespectrais são aqueles em que o número de intervalos espectrais é pequeno e tais intervalos abrangem uma variação considerável de comprimentos de onda (em geral superiores a 10 nm). Embora atualmente existam sensores com resoluções espectrais mais acuradas, os sensores multiespectrais ainda são de grande interesse para a comunidade científica e usuários em geral, uma vez que suas bandas podem estar posicionadas em regiões estratégicas do espectro eletromagnético, e, em se tratando de sensoriamento remoto orbital, o imageamento multiespectral têm se destacado em relação aos dados hiperespectrais com relação à resolução espacial.

Diversos estudos foram desenvolvidos nas últimas décadas utilizando dados multiespectrais na detecção de clorofila *a* e outras variáveis da qualidade da água, mas é necessário cautela na manipulação desses dados, pois, como afirma Rudorff (2006), em investigações de sensoriamento remoto óptico é necessário conhecer as origens dos fluxos de radiação que atingem o sensor. Comparando-se sistemas aquáticos a terrestres, a diferenciação das componentes radiativas é ainda mais importante, pois a energia proveniente dos sistemas aquáticos é relativamente baixa.

De acordo com Jensen (2009), a radiação registrada por um sensor é uma função da energia eletromagnética proveniente de quatro fontes. Rudorff (2006) cita as componentes originárias do espalhamento pela atmosfera (1), das reflexões especulares da radiação solar direta e difusa (2), do fluxo de radiação emergente da água que interage na coluna (3) e a componente que alcança o fundo do corpo d'água (4). Apenas o fluxo emergente da coluna traz informações sobre as substâncias em suspensão na coluna d'água sendo, portanto, o único de interesse para o sensoriamento remoto. A influência dos demais fluxos pode ser maior ou menor, dependendo das condições físicas no momento da detecção da radiância (*L*) pelo sensor (por exemplo, elevação solar e atmosfera). A Figura 7 mostra os processos que ocorrem na interação da radiação com corpos d'água até chegar ao sistema sensor.






Figura 7 - Fluxos de radiação detectados por sensores remotos para sistemas aquáticos.
Fonte: Rudorff, 2006.

Jensen (2009) apresenta uma descrição matemática deste processo, considerando L_t a radiância total que chega ao sistema sensor:

$$L_t = L_p + L_s + L_v + L_b \quad (1)$$

Onde:

L_p é a porção da radiação registrada pelo sistema sensor resultante da radiância solar e da atmosfera que não chega na superfície da água, é a componente da radiação espalhada pela atmosfera e alvos adjacentes,

L_s é a fração da radiância proveniente do sol e da atmosfera que penetra apenas alguns milímetros na coluna d'água ou é refletida diretamente pela superfície d'água. Ocorre quando o ângulo zenital solar e o ângulo de visada do sensor são aproximadamente idênticos e é chamada de reflexão especular;

L_v é a radiância do sol e da atmosfera que penetra na superfície d'água e interage com os constituintes orgânicos e inorgânicos da água, saindo da coluna d'água sem chegar ao fundo (chamada de radiância volumétrica de subsuperfície);

L_b é a radiância que interage com a atmosfera, a coluna d'água, o fundo do ambiente e é propagado novamente, deixando a coluna d'água (radiação refletida pelo fundo).



A presença deste fluxo de radiação provoca um aumento do sinal resultante, o que dificulta a análise dos constituintes da água.

Kirk (1994) afirma que apenas a radiância de sub-superfície (L_v) contém informação sobre a composição da coluna d'água e que o problema essencial é quantificar o fluxo emergente desta radiação na presença dos outros fluxos.

De modo geral, o processo de formação de uma imagem multiespectral baseia-se na medida da radiância dos alvos da superfície que são registrados em tons de cinza pelos detectores dos sensores. Uma vez que o sinal registrado pelo sensor é quantizado em níveis de cinza, faz-se necessária a conversão desses valores para uma grandeza física, que seja relacionada diretamente ao processo de interação da radiação entre “sol - alvo - sensor”. Esse processo de transformação, que é exatamente o processo inverso da formação de uma imagem, passa pela conversão dos valores de brilho para radiância, que é a quantidade de radiação que deixa uma superfície (alvo) por unidade de área em uma dada direção. A radiância, então, relaciona-se então ao estágio de interação “alvo - sensor” da radiação.

Entretanto, se o intuito é obter informações acerca do alvo propriamente dito, é adequado que se faça uma conversão dos valores de radiância para reflectância, já que essa medida relaciona a quantidade de radiação recebida e refletida pelo alvo.

Ainda é válido lembrar, que tanto para medidas de radiância quanto de reflectância de um alvo, deve-se considerar a contribuição da atmosfera, já que essa também interfere no sinal registrado pelo sensor. Barbosa (2005) afirma que na região visível do espectro eletromagnético, os principais processos que contribuem para o componente atmosférico do sinal registrado pelo sensor são o espalhamento molecular (Rayleigh), as absorções por vapor d'água, ozônio e outros gases, e a absorção e espalhamento por partículas em suspensão. Segundo Zullo Jr. (1994), os efeitos nas imagens desses processos atmosféricos são a diminuição da faixa de valores digitais possíveis registrados pelo sensor, diminuição de contraste entre superfícies adjacentes e alteração do brilho de cada ponto da imagem.

Modelos de transferência radiativa são bastante utilizados para a correção atmosférica. Isso porque tais modelos são baseados nas características de absorção e espalhamento da radiação pela atmosfera, inferidas a partir de variáveis como vapor d'água, espessura de aerossóis e visibilidade no momento de aquisição da cena. Como citam Ponzoni e Shimabukuro (2007), esses modelos apresentam como principal vantagem o fato de



considerarem o fenômeno da absorção da radiação eletromagnética, o que implica em resultados frequentemente mais confiáveis quando o interesse é correlacionar os valores de reflectância presentes nas imagens com parâmetros geofísicos ou biofísicos de objetos da superfície terrestre.

Dentre os modelos de transferência radioativa têm-se o modelo conhecido como MODTRAN - *Moderate Atmospheric Radiance and Transmittance*, que está implementado no aplicativo ENVI, no módulo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*). Como o próprio nome diz, o FLAASH foi desenvolvido para correção de dados hiperespectrais, onde o intuito é extrair as informações atmosféricas das próprias bandas do sensor, mas também é possível sua aplicação para dados multiespectrais, uma vez que é possível dar entrada aos parâmetros atmosféricos necessários e escolher modelos adotados como padrão, dependendo da localização em que a cena foi tomada.

Como cita Rudorff (2006), os dados de sensoriamento remoto coletados em ambientes aquáticos apresentam outros fatores que geralmente não são considerados nos modelos atmosféricos, como os efeitos de reflexão especular e o espalhamento múltiplo pela interface ar/água e pela coluna d'água. Entretanto, frente à falta de modelos mais refinados, o FLAASH têm sido utilizado para correção atmosférica de dados de sensoriamento remoto de ambientes aquáticos, como é o caso de Ennes (2008).

2.2. PIGMENTOS FITOPLANCTÔNICOS: CLOROFILA A

2.2.1. IMPORTÂNCIA ECOLÓGICA E CARACTERÍSTICAS DO FITOPLÂNCTON

Em qualquer ecossistema, a circulação de matéria e energia está relacionada a três etapas: produção, consumo e decomposição. Na produção, a captação e transformação da energia pelos produtores possibilitam a síntese de matéria orgânica a partir de matéria inorgânica, sendo os organismos envolvidos nessa etapa chamados de autotróficos. A matéria orgânica sintetizada na produção é utilizada direta ou indiretamente na etapa de consumo, para fornecer energia aos organismos que não são capazes de obtê-la de forma autônoma. A



terceira etapa, chamada de decomposição, é efetuada, principalmente, por fungos e bactérias, que decompõem a matéria orgânica novamente em matéria inorgânica. Trata-se de uma etapa fundamental para a circulação dos nutrientes e possibilita o reaproveitamento desses pelos organismos produtores. Pereira Filho (2000) apresenta um esquema simplificado do metabolismo no meio aquático (Figura 8).




Figura 8 - Representação simplificada do metabolismo do ecossistema aquático.
Fonte: Pereira Filho, 2000.

Nesse contexto, a energia que flui nos ecossistemas aquáticos depende, em grande parte, dos produtores primários fotoautotróficos (que utilizam a luz solar) e, em menor escala, das bactérias quimiossintetizantes, pois mesmo esses seres dependem da matéria inorgânica produzida pelos seres fotoautotróficos (TUNDISI; TUNDISI, 2008).

Segundo Wetzel (2001), o fitoplâncton consiste no grupo de pequenas plantas ou bactérias fotossintetizantes que possui nenhuma ou limitada locomoção, estando sujeitos aos movimentos da água. Algumas espécies movem-se utilizando seus flagelos ou possuem mecanismos que alteram sua flutuabilidade. Entretanto, a maioria flutua livremente na coluna d'água. Sua existência é observada principalmente em ambientes lênticos e em grandes rios com baixa correnteza. O referido autor ainda destaca que o estudo do fitoplâncton têm sido uma das mais populares áreas da ecologia de ambientes aquáticos nas últimas décadas e muitos avanços têm sido feitos no entendimento de sua dinâmica.

Com relação aos fatores limitantes e controladores do fitoplâncton, Tundisi e Tundisi (2008) apresentam as principais características, destacando que a qualidade e quantidade de luz interferem na fisiologia, crescimento e reprodução desses organismos. Assim, da mesma forma que uma baixa intensidade luminosa pode limitar a fotossíntese, altas intensidades também podem inibi-la. A temperatura também interfere na taxa de saturação de fotossíntese, ou seja, o aumento na temperatura faz com que o ponto de saturação de fotossíntese também aumente.


Quanto aos nutrientes, os principais a serem considerados para desenvolvimento do fitoplâncton são nitrogênio, fósforo, carbono, oxigênio, hidrogênio e enxofre. Os três primeiros são considerados limitantes, uma vez que o nitrogênio é necessário para síntese de aminoácidos e proteínas e o fósforo para sínteses moleculares e transporte de íons (ATP). É válido lembrar que o potencial de óxido-redução também interfere na disponibilidade das formas químicas dos nutrientes (TUNDISI; TUNDISI, 2008). Ainda, segundo os autores, o dióxido de carbono (CO₂) utilizado na fotossíntese e em sistemas de pH baixo pode ser também limitante ao crescimento do fitoplâncton. Quanto ao oxigênio, embora seja um produto da fotossíntese, também é considerado um fator limitante, visto que poucas espécies altamente especializadas sobrevivem a ambientes anóxicos.

É conhecido que a clorofila é um dos principais pigmentos fotossintetizantes de organismos vivos, juntamente com os carotenóides e ficobilinas. De acordo com Hall e Rao (1980), os carotenóides e ficobilinas são chamados de pigmentos fotossintéticos acessórios, uma vez que a energia absorvida por esses pigmentos tende a ser transferida para a clorofila.

Devido à diversidade de organismos capazes de realizar a fotossíntese e à diversidade de estrutura desses seres, distinguem-se três tipos principais de clorofila, os quais diferem nos detalhes de sua estrutura molecular e nas suas propriedades específicas de absorção. De acordo com APHA (1998), a clorofila *a* é a mais comum das clorofilas e representa, aproximadamente, de 1 a 2% do peso seco do material orgânico em todas as algas planctônicas sendo, portanto, considerada um indicador da biomassa algal. Assim, a clorofila *a* é considerada a principal variável indicadora de estado trófico dos ambientes aquáticos.



A fórmula molecular da clorofila *a* é $C_{55}H_{72}N_4O_5Mg$ e foi determinada por Fischer, na Alemanha em 1940 e confirmada em 1960 por pesquisadores de Havard. A molécula de clorofila contém uma parte superior porfirínica e uma extensão de fitol. O núcleo porfirínico polar (solúvel em água) é composto de um anel tetrapirrólico e um átomo de magnésio (HALL; RAO, 1980). A Figura 9 apresenta a estrutura química da clorofila *a*.



Fonte: Adaptado de Streit et al., 2005.

De acordo com Kluge (2004 apud STREIT et al, 2005) a energia absorvida pelos pigmentos envolvidos na fotossíntese é transferida para sítios bem definidos da célula vegetal, os chamados centros de reação. Há dois centros de reação, um deles absorvendo em 680 nm e outro em 700 nm, os quais interagem entre si através de transportadores de elétrons. É a partir da molécula de clorofila, a qual absorve em 680 nm no espectro visível, que os elétrons oriundos da água são transferidos para a cadeia transportadora de elétrons da fotossíntese.

FERREIRA, M. S.






Figura 10 - Espectro de absorção da clorofila a.

Fonte: Adaptado de Kirk, 1994.

Como pode ser observado na Figura 10, a clorofila *a* apresenta forte absorção na região da luz vermelha e também próximo à região do azul, esta última denominada banda de Soret (KIRK, 1994). De acordo com Guizado (2008), a banda de Soret é característica de compostos porfirínicos, como é o caso do pigmento em questão. A absorção da clorofila é muito baixa na região da luz verde, fato pelo qual a clorofila apresenta essa coloração.

A fluorescência é a denominação que se dá ao espalhamento inelástico de luz gerado pelo decaimento de estados excitados para o estado fundamental em intervalo de tempo menor que 10^{-5} s (SKOOG & LEARY, 1992 apud BARBOSA, C., 2003). Trata-se de um fenômeno de emissão de energia visível imediatamente após o estímulo de um átomo por radiação eletromagnética. A clorofila *a* possui propriedades fluorescentes graças à sua estrutura molecular, desse modo, a Figura 11 apresenta os espectros de excitação e emissão desse pigmento.






Figura 11 - Espectros de excitação e emissão de fluorescência da clorofila a.
FONTE: Adaptado de Turner Designs, 1998.

À esquerda na Figura 11 tem-se o espectro de excitação da clorofila. Para a obtenção desse espectro é necessário medir a luminescência em um comprimento de onda fixo, enquanto o comprimento de onda de excitação varia. Holler et al. (2009) citam que, uma vez que a primeira etapa para gerar emissão de fluorescência é a absorção de radiação para criar estados excitados, um espectro de excitação é essencialmente idêntico a um espectro de absorção obtido sob as mesmas condições. Assim, de maneira análoga à absorção mostrada na Figura 10, o espectro de excitação da clorofila *a* apresenta um pico de fluorescência entre 400 a 450 nm.

O espectro de emissão é obtido ao irradiar-se uma amostra com um comprimento de onda de excitação fixo e medir a intensidade da luz reemitida, numa faixa espectral definida. O comprimento de onda de excitação ideal para registrar o espectro de emissão de um composto fluorescente determinado é, em geral, escolhido em função de seu espectro de absorção. Na maior parte dos casos, este comprimento de onda corresponde ao máximo de absorção (SIERRA et al., 1995). Na Figura 11, o espectro localizado à direita da figura, representa a emissão de fluorescência da clorofila *a* quando excitada a partir do comprimento de onda do pico de absorção, ou de excitação. Em concordância com Guizado (2008) que analisou o espectro de fluorescência da porfirina, a clorofila *a*, quando irradiada com luz azul, mostra intensa fluorescência na região da luz vermelha.



2.2.3. MÉTODOS DE QUANTIFICAÇÃO DE CLOROFILA *A*

Baseado em suas propriedades espectrais, três métodos podem ser utilizados para determinação de clorofila *a*: espectrofotometria, fluorimetria e cromatografia líquida de alta resolução (HPLC). O método laboratorial mais empregado é o espectrofotométrico, que se baseia na absorção de luz em comprimentos de onda definidos. Este método tem a desvantagem de requerer volumes relativamente grandes de amostras de água, principalmente em situações de baixa concentração de pigmentos. Neste caso, a fluorimetria desponta como método mais prático quando se deseja avaliar um número grande de pontos amostrais e para determinações *in vivo*. Por sua vez, o HPLC é útil para quantificar uma vasta gama de pigmentos fotossintéticos, incluídos clorofila *a*, pigmentos acessórios (como clorofilas *b* e *c*) e produtos de degradação de clorofilas (MARTINI et al., 2006).

Os métodos de quantificação de clorofila baseados na extração do pigmento geralmente utilizam solventes orgânicos, pois, conforme citam Streit et al. (2005), as ligações entre as moléculas de clorofilas são muito frágeis (não-covalentes), rompendo-se com facilidade ao se macerar o tecido em solventes orgânicos.

O caráter hidrofílico/hidrofóbico de uma substância influi diretamente na escolha do melhor solvente para a sua extração. Os solventes polares como a acetona, o metanol, o etanol, o acetato de etila, a piridina e a dimetilformamida são os mais eficazes para a extração completa das clorofilas. Os solventes apolares como o hexano e o éter de petróleo são os menos eficazes (MUSSI, 2003; VON ELBE, 2000 apud STREIT et al. 2005). Golterman et al. (1978) e APHA (1998) recomendam a utilização de acetona 90%. A essa solução de acetona é acrescido carbonato de magnésio ($MgCO_3$) que reage com a molécula de clorofila evitando a degradação.

Segundo Barroso (1998 apud STREIT et al., 2005), os dois produtos da degradação da clorofila *a*, o feoforbídeo *a* e a feofítina *a*, podem interferir na determinação da clorofila *a* por absorverem luz e fluorescerem na mesma região do espectro. Se esses feopigmentos estiverem presentes na amostra, poderão ocorrer erros significativos na concentração de clorofila *a*.

Nesse sentido, todas as metodologias de determinação de clorofila *a* extraída das células algais buscam minimizar a degradação das amostras e conseqüente interferência de



feopigmentos. Recomenda-se que a extração e determinação da clorofila *a* sejam feitas sob baixa luminosidade, sempre mantendo o cuidado com a temperatura de armazenamento das amostras, caso a determinação de clorofila não seja feita imediatamente após a coleta.

Por outro lado, além das técnicas baseadas na extração, tem-se a determinação *in vivo* da concentração de clorofila *a*. Tal procedimento só pode ser efetuado através de técnicas fluorimétricas, como dito anteriormente, pelo fato de não necessitar de um tratamento especial das amostras. Atualmente existem no mercado equipamentos com capacidade de realizar medidas de parâmetros da qualidade da água *in vivo* por fluorescência, sem a necessidade de filtragem para extração ou tratamento químico. Essas medidas podem ser feitas usando amostras pontuais ou em fluxo contínuo no ambiente natural com células vivas. A vantagem desse tipo de análise é a rapidez e a possibilidade de aquisição de um conjunto maior de medidas, já que elimina a etapa de extração e análises em laboratório (TURNER DESIGNS, 2004).

2.3. INFERÊNCIA ESPACIAL POR REDES NEURAS ARTIFICIAIS

Modelos ambientais são representações matemáticas criadas para descrever fenômenos ou processos do mundo real. São simplificações da realidade, de onde se abstraem os elementos mais importantes para uma aplicação, e são construídos a partir da observação dos dados espaciais e seus relacionamentos. Os modelos ambientais são usados para aumentar o conhecimento sobre um processo, prever valores ou comportamentos em áreas não observadas e comprovar, ou não, hipóteses feitas sobre processos (MOORE et al., 1993 apud FELGUEIRAS, 1999).

De acordo com Câmara et al. (2001), os modelos de processos ambientais no contexto de SIG, podem ser descritos como a combinação de um conjunto de dados de entrada através de uma função, produzindo um novo dado de saída. Essa função pode tomar muitas formas diferentes, mas os relacionamentos expressos por esta função são baseados no entendimento teórico de princípios físicos e químicos, ou são empíricos, baseados em dados observados ou ainda na combinação destes dois tipos.



Os modelos empíricos são aqueles baseados em relacionamentos estatísticos ou relacionamentos heurísticos e podem ser divididos em modelos baseados em conhecimento, que são implementados a partir do conhecimento de especialistas, e modelos baseados em dados, que são implementados a partir de um conjunto de dados observados (CÂMARA et al., 2001).

Dados de sensoriamento remoto podem ser utilizados como conjunto de entrada para modelos empíricos baseados em dados em inferência geográfica. A seguir, são apresentadas as principais características de Redes Neurais Artificiais, visto que se trata de um método de inferência espacial utilizado nesse trabalho.

2.3.1. REDES NEURAS ARTIFICIAIS

De acordo com Haykin (1999), uma Rede Neural Artificial (RNA) é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ele se assemelha ao cérebro humano em dois aspectos: (1) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; e (2) forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Para Santos (2001), redes neurais artificiais consistem de várias unidades de processamento (neurônios artificiais) interconectadas entre si, formando uma determinada disposição estrutural de camadas e conexões entre estas.

Como mencionado, o neurônio artificial é a unidade fundamental de processamento de uma RNA, o qual recebe uma ou mais entradas, transformando-as em saídas. Cada entrada possui um peso associado, que indica sua influência na saída do neurônio. Assim, o esquema de um neurônio artificial pode ser visto na Figura 12.






Figura 12 - Modelo de um neurônio não linear.

Fonte: Haykin, 1999.

Baseando-se na Figura 12, é possível distinguir três elementos que Haykin (1999) considera como básicos na estrutura de um neurônio artificial:

- Sinapses (conexões): caracterizadas por um peso (w), que pode representar a sua intensidade. O papel do peso w_{kj} é ponderar 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 é inibitória (BRONDINO, 1999);
- Somatório: realiza a soma das entradas, ponderadas pelos seus respectivos pesos, ou seja, a saída u_k é definida por

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

- Função de ativação: funciona como um fator limitante à amplitude de saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, comumente $[0,1]$ ou $[-1,1]$ (BRONDINO, 1999).

A Figura 12 também inclui um *bias* aplicado externamente, representado por b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente (HAYKIN, 1999).

A função de ativação (ϕ) define o nível de ativação do sinal de entrada, ou seja, tem a finalidade de calcular um novo estado de ativação para o elemento de processamento (EP). A função converte a somatória da ativação das entradas em ativação de saída. Esta



função diferencia a decisão neural baseada no potencial interno do neurônio e determina o valor a ser enviado aos demais neurônios. Modelos lineares, rampa, degrau (*threshold*), gaussiana, sigmóides e tangentes hiperbólicas são as funções de ativação mais comumente utilizadas (SANTOS, 2001). As funções de ativação apontadas por Braga et al. (2000) como principais são apresentadas na Figura 13.




Figura 13 - Funções de ativação mais utilizadas em RNA.
Fonte: Adaptado de Braga et al., 2000.

Em uma rede neural, os elementos de processamento estão distribuídos em camadas e, de acordo com Braga et al. (2000), o número de camadas da rede, número de elementos em cada camada, tipo de conexão entre os EPs e topologia da rede definem sua arquitetura.

Quanto ao número de camadas, uma RNA pode ser classificada como rede de camada única ou redes de múltiplas camadas. A rede de múltiplas camadas (Figura 14) se distingue pela presença de uma ou múltiplas camadas escondidas, em que os EPs são chamados de unidades escondidas. A função dessas unidades é intervir entre a entrada externa

e a saída da rede, de alguma maneira útil. Ao adicionar uma ou mais camadas escondidas, a rede se torna capaz de extrair estatísticas de ordem mais alta (TRONTO, 2007).




Figura 14 - Estrutura de uma rede neural de múltiplas camadas.

Fonte: Gonzalez e Woods, 2000.

Nessas redes, conhecidas também como *Multi Layer Perceptron* (MLP), cada camada tem uma função específica. A camada de saída recebe os estímulos das camadas intermediárias e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação do problema, mais rica e complexa (CARVALHO, 2009).

No que diz respeito aos tipos de conexões, as redes neurais artificiais podem ser do tipo *feedforward*, ou acíclicas, nas quais a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de EPs em camadas de índice menor ou igual a i ou podem ser do tipo *feedback*, ou cíclicas, quando esse tipo de operação é permitido. Por fim, as redes também podem ser classificadas quanto à sua conectividade (topologia) como completamente conectadas ou parcialmente conectadas (BRAGA et al., 2000).

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas através de RNAs. A generalização, que está associada à capacidade de a rede aprender através de um conjunto de exemplos e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das redes neurais vai muito além do que simplesmente



mapear relações de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícita através dos exemplos (BRAGA et al., 2000).

Ainda, de acordo com Bocanegra (2002), a propriedade que mais se assemelha às características humanas é a habilidade de aprender. Ao invés de especificar todos os detalhes de uma computação, tem-se a possibilidade de treinar uma rede para fazer esse cálculo. Isso significa que se podem tratar problemas onde regras apropriadas são muito difíceis de conhecer *a priori*. O objetivo do treinamento de uma RNA é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas consistentes.

Diversos métodos de treinamento de redes foram desenvolvidos, podendo ser agrupados em paradigmas de aprendizado. O aprendizado é classificado de acordo com seu ambiente de funcionamento. Nesse contexto, Santos (2001) comenta os seguintes paradigmas de aprendizado:

- Aprendizado Supervisionado: quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- Aprendizado Não Supervisionado (auto-organização): quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- Reforço: quando um crítico externo avalia a resposta fornecida pela rede.

Segundo Haykin (1999), as redes do tipo MLP têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado retro-propagação do erro (*error backpropagation*). Esse algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento. Segundo Lippmann (1987), o 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 o erro médio quadrático) entre a saída calculada por um 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.

De acordo com Gonzalez e Woods (2000), o processo de treinamento de uma rede multicamadas feito pelo algoritmo *backpropagation* começa com a definição de um conjunto arbitrário de pesos para as conexões da rede. Trata-se de um processo iterativo e envolve duas fases distintas em cada ciclo de iteração. Na primeira, um vetor de treinamento com a



respectiva saída desejada é apresentado à rede e propagado através de suas camadas para computar uma saída para cada nó. As saídas dos nós da última camada são comparadas com as saídas desejadas e, a partir disso, termos de erro são gerados. A segunda fase envolve uma passagem de volta através da rede a partir da última camada, durante a qual o erro é repassado para cada nó e os pesos correspondentes são alterados. Em uma sessão de treinamento bem sucedido, este erro diminui com o aumento do número de iterações e o procedimento converge para um conjunto estável de pesos.

Cabe salientar que a partir do algoritmo *backpropagation* clássico, foram desenvolvidas várias adaptações do mesmo, as quais visam se adaptar melhor ao conjunto de dados do usuário e à finalidade da rede neural.

2.3.2. UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA INFERÊNCIA EM SENSORIAMENTO REMOTO

Como citam Atkinson e Tatnall (1997), RNAs têm sido utilizadas em sensoriamento remoto para diversas finalidades, tais como classificação, integração de dados multifonte, classificação Fuzzy, combinação com técnicas estatísticas convencionais, inferência de variáveis biofísicas, verificação de correspondência de feições em imagens e mapas topográficos, dentre outros. Pela Figura 15, pode-se observar a evolução dos estudos de sensoriamento remoto que utilizaram RNAs.




Figura 15 - Número de estudos utilizando RNAs publicados nos quatro principais periódicos de Sensoriamento Remoto.
Fonte: Mas e Flores, 2008.



Os números da Figura 15 referem-se aos periódicos de maior impacto na área de sensoriamento remoto (*IEEE Transactionson on Geoscience and Remote Sensing*, *International Journal of Remote Sensing*, *Photogrammetric Engineering and Remote Sensing* e *Remote Sensing of Environment*). Em termos gerais, percebe-se que o número de publicações aumentou cerca de quatro vezes entre 1990 e 2005.

A crescente aceitação do uso de redes neurais em sensoriamento remoto deve-se à sua capacidade de (i) aprender padrões complexos, tendo em consideração qualquer relação não-linear complexa entre as variáveis explicativas e as dependentes; (ii) generalização em ambientes ruidosos, o que torna as soluções de RNAs robustas na presença de dados incompletos ou imprecisos; (iii) incorporar conhecimento *a priori* e restrições reais na análise dos dados; (iv) integrar diferentes tipos de dados para a análise devido à ausência de pressupostos sobre o conjunto de dados (MAS; FLORES, 2008).

A principal utilização de redes neurais artificiais em sensoriamento remoto é para classificação de cobertura da terra, entretanto outros usos são igualmente possíveis e tem apresentado resultados satisfatórios. Os trabalhos de Atkinson e Tatnall (1997) e Mas e Flores (2008) apresentam diferentes abordagem de utilização de RNAs e os trabalhos relacionados.

Uma das possíveis aplicações de redes neurais artificiais é na inferência de parâmetros biofísicos a partir de dados de sensoriamento remoto. De modo geral, os dados de sensoriamento servem como dados de entrada da rede, dos quais uma amostra de treinamento é apresentada à mesma e, após a definição da arquitetura, a rede neural é capaz de produzir uma saída numérica para o parâmetro estudado. Essa abordagem de uso de RNAs e dados de sensoriamento remoto tem sido aplicada para várias áreas do conhecimento como meteorologia (JANG et al., 2004), agricultura (DANSON et al., 2003), pedologia (CHANG; ISLAM, 2000), oceanografia (BUKTON et al., 1999; GROSS et al., 2000; KEINER; BROWN, 1999; KEINER; YAN, 1998; SCHILLER; DOERFFER, 1999), dentre outros.

Os estudos oceanográficos citados buscam a inferência de componentes opticamente ativos presentes em águas oceânicas. No trabalho de Keiner e Yan (1998) foi realizada a inferência espacial de clorofila e sedimentos em suspensão a partir de imagens TM/Landsat. Os autores fizeram a comparação dos resultados obtidos pela inferência utilizando regressão múltipla e redes neurais e obtiveram resultados superiores com o uso de RNAs.



Os trabalhos de Bukton et al. (1999), Schiller e Doerffer (1999), Keiner e Brown (1999) e Gross et al. (2000) buscaram obter, por diferentes abordagens, um modelo inverso de transferência radiativa para a obtenção da concentração de componentes opticamente ativos distintos através de dados de sensores específicos para estudos oceânicos (MERIS e SeaWiFS).

Desse modo, percebe-se pela literatura, que RNAs têm proporcionado bons resultados na modelagem entre as grandezas medidas por sensores remotos (radiância, reflectância) e parâmetros limnológicos tais como a clorofila *a*.



3. CARACTERIZAÇÃO DA ÁREA DE ESTUDOS

3.1. DEFINIÇÃO DA ÁREA DE ESTUDOS

Para a realização deste trabalho, foi necessária a obtenção de dados de campo a respeito da concentração de clorofila *a* em uma área de estudo, a qual foi definida segundo critérios de localização geográfica do recurso hídrico e logística apropriada para realização de campanhas de campo, bem como o conhecimento prévio de atividade fitoplanctônica.

Analisando-se dados de qualidade da água do estado de São Paulo coletados por CETESB (2009), pôde-se verificar que o reservatório Cascata, corpo d'água localizado no município de Marília, apresentou altos teores de clorofila *a*, durante todas as amostragens realizadas no local, inclusive apresentando valores que ultrapassam os limites estabelecidos pela legislação específica (Resolução CONAMA 357/05). Assim, partiu-se para uma análise temporal, visando verificar se tal comportamento é típico ou trata-se de um fato isolado. Para tal análise foram considerados dados do Relatório de Qualidade das Águas do Estado de São Paulo, elaborados pela CETESB, em anos anteriores que são apresentados na Figura 16.




Figura 16 - Análise temporal de clorofila no reservatório Cascata.



Os valores de concentração de clorofila *a* mostram que o ambiente citado apresentou alta atividade fitoplanctônica durante todo o período analisado, e, portanto, considerou-se um corpo d'água que atende aos requisitos necessários para a execução da pesquisa.

Como especificado anteriormente, o corpo d'água está localizado no município de Marília, SP, e pertence à Unidade de Gerenciamento de Recursos Hídricos do rio Aguapeí (UGRHI 20). Possui uma área de 7,342 ha e se constitui de um manancial de abastecimento de água do município, gerenciado pelo Departamento de Água e Esgoto de Marília (DAEM). O reservatório pode ser visualizado na Figura 17.




Figura 17 - Localização geográfica do reservatório Cascata.

Percebe-se que o corpo d'água encontra-se em perímetro urbano e não possui vegetação ciliar no entorno, estando suscetível à carga de poluentes tanto de maneira pontual quanto difusa.



3.2. CARACTERIZAÇÃO LIMNOLÓGICA BÁSICA DO RESERVATÓRIO

Paralelamente à campanha de campo visando a coleta de dados fluorimétricos e espectrorradiométricos, foi feito um levantamento exploratório de variáveis limnológicas que possibilitaram caracterizar o ambiente em estudo. A obtenção de tais dados ocorreu em março de 2011 e foram coletadas as seguintes variáveis limnológicas: temperatura, pH, turbidez e profundidade do disco de Secchi, cujos valores obtidos são apresentadas na Figura 18, com exceção dos valores de temperatura.




Figura 18 - Medições de variáveis limnológicas no reservatório Cascata.

Para todas as variáveis analisadas, percebe-se que os valores encontrados para os elementos amostrais não apresentam grande variação. A temperatura média do corpo d'água registrada no levantamento foi de 28,55 °C e o pH apresentou um valor médio de 5,8, com um desvio padrão de 1,24.

É interessante destacar que os valores de disco de Secchi apresentaram pouca variação, com desvio padrão igual a 0,05, enquanto os valores de turbidez variaram consideravelmente, com um desvio padrão de 1,78. Tais variáveis, de acordo com suas respectivas definições, apresentam correlação negativa, uma vez que aumentando a quantidade de material particulado na água (ou seja, aumentando a turbidez), a luz penetra a uma menor profundidade na água (diminuindo a profundidade do disco de Secchi). No caso



do reservatório Cascata não foi encontrada correlação significativa entre os dados, o que pode ser devido às condições de iluminação instáveis, comprometendo a aquisição das medidas de profundidade de Secchi.

Ante o exposto, verificou-se um comportamento similar em relação às todas as variáveis limnológicas observadas, sem grandes variações, um forte indício de águas homogêneas. A homogeneidade das águas do reservatório Cascata pode ser justificada pela sua pequena área e a ausência de fontes pontuais de poluição de alto impacto no recurso hídrico.



4. ESCOPO GERAL DA INVESTIGAÇÃO

4.1. MATERIAL

4.1.1. IMAGENS ORBITAIS

- **Imagem multiespectral World View-2**

A definição do sensor é dependente das características espectrais do fenômeno que se pretende estudar e das dimensões da área de estudos. No caso dessa pesquisa, a área de estudo é de pequena extensão, assim, a alternativa operacional foi a utilização de imagens de alta resolução espacial.

Com relação às características espectrais, grande parte dos sensores de alta resolução espacial apresenta bandas de resolução grosseira e pouco adequadas ao estudo de pigmentos fitoplanctônicos na água. Nesse cenário, desponta como alternativa viável e adequada o sensor World View-2. Como pode ser observado na Figura 19, as bandas espectrais contemplam grande parte da faixa espectral onde há resposta dos pigmentos fotossintetizantes.




Figura 19 - Comportamento espectral de água com presença de algas e faixas espectrais imageadas pelo sensor World View-2.

Trata-se de um sensor desenvolvido pela empresa Digital Globe que é considerado o sucessor da série QuickBird. Segundo a empresa, o World View-2 é o primeiro sensor comercial a fornecer imagens de alta resolução espacial em 8 bandas multiespectrais. No Quadro 1 observam-se as principais características desse sensor.

Lançamento	08/10/2009
Órbita	Heliosíncrona
Altitude	770 km
Resolução espacial	0,46 m no modo pancromático 1,84 m no modo multiespectral
Bandas espectrais	8 (Costal, Azul, Verde, Amarelo, Vermelho, Vermelho limítrofe, IVP-1, IVP-2)
Resolução radiométrica	11 bits

Quadro 1 - Características do sensor World View-2.

Fonte: Adaptado de Digital Globe, 2010.

- **Imagem do sensor MODIS/TERRA**

O sensor MODIS (MODerate-resolution Imaging Spectroradiometer) possui alta sensibilidade radiométrica (12 bits) em 36 bandas espectrais contidas no intervalo de 0,4 a 14,4 μm do espectro eletromagnético. Duas bandas são adquiridas na resolução de 250m, outras cinco bandas na resolução de 500m e as demais 29 bandas em 1 km. A varredura de 55° para cada lado na órbita de 705km de altura resulta numa faixa imageada de 2330 km, com cobertura global em 2 dias (RUDORFF et al., 2007).

As 36 bandas espectrais do MODIS estão localizadas em função de um comprimento de onda cuidadosamente escolhido para a observação de feições das propriedades das nuvens, dinâmica e as propriedades da vegetação na cobertura terrestre, e a temperatura da superfície dos oceanos no mundo. Devido à localização de suas bandas espectrais, o MODIS pode gerar dados sobre características de nuvens e de concentrações de aerossóis, entre outros, o que pode ajudar na calibração de modelos matemáticos que executem correção atmosférica.



Para este trabalho, a concentração de vapor d'água, necessária na correção atmosférica pelo ENVI-FLAASH, foi obtida no produto MOD07_L2, na imagem "water_vapor". A imagem utilizada foi tomada pelo sensor a bordo da plataforma TERRA, cujo horário de aquisição foi próximo ao horário de tomada da imagem World View-2.

4.1.2. INSTRUMENTOS DE MEDIÇÕES IN SITU

- **Fluorômetro de campo**

O fluorômetro de campo é o equipamento responsável pela aquisição de medidas da concentração de clorofila *a* através de sua fluorescência. O equipamento utilizado é do modelo 10-AU, da empresa Turner Designs, e adquire medidas pontuais e em fluxo contínuo.

O fluorômetro 10-AU oferece medidas diretas de fluorescência de clorofila *a* e pigmentos fitoplanctônicos em células algais vivas. Pelo fato de não necessitar de um tratamento especial das amostras, a técnica de fluorescência *in vivo* (Fiv) é ideal para a definição de perfis em tempo real (TURNER DESIGNS, 2004). Desse modo, o equipamento coleta medidas de fluorescência *in vivo* e relaciona tais medidas a um valor "relativo" de concentração de clorofila *a*, sendo necessária a posterior calibração do equipamento para determinação de valores absolutos do pigmento.

Abaixo, tem-se a configuração típica de um fluorômetro para detecção de clorofila *a* (Figura 20).




Figura 20 - Configuração do fluorômetro para a detecção de clorofila *a*.
FONTE: Adaptado de Turner Designs, 2004.



Pela Figura 20 nota-se que a configuração de um fluorômetro para detecção de clorofila *a* obedece as propriedades fluorescentes da variável apresentada na Figura 11 (pg. 34). Nesse sentido, o comprimento de onda selecionado para excitação da clorofila é localizado na região do azul, enquanto que o filtro utilizado para capturar a emissão de fluorescência da mesma é localizado na região do vermelho, depois disso, a radiação emitida por fluorescência é convertida em um sinal elétrico para sua quantificação.

- **Espectrorradiômetro de campo**

O espectrorradiômetro foi utilizado para a obtenção das curvas de reflectância de elementos amostrais proporcionando o conhecimento do comportamento espectral das águas do reservatório.

O equipamento utilizado é do modelo ASD FieldSpec Handheld, operando em 512 canais no intervalo espectral de 325-1075 nm, com resolução espectral de 1,6 nm, diminuindo sua resolução para 3,5 nm próximo a 700nm. O sinal coletado pelo equipamento é quantizado em 16 bits (ASD Inc., 2002).

- **Receptores GPS**

Necessários para a correta localização dos elementos amostrais onde foram feitas as mensurações em campo e posterior registro com os dados de sensoriamento remoto.

- **Equipamentos de análise limnológica**

Foram utilizados equipamentos de análise limnológica em campo, para caracterização dos elementos amostrais. Os instrumentos utilizados foram pHmêtro, oxímetro, turbidímetro, condutivímetro, disco de Secchi.



4.1.3. SOFTWARES

- **Simulador de Redes Neurais da Universidade de Stuttgart: SNNS**

O SNNS (*Stuttgart Neural Network Simulator*), disponível em <http://www.ra.cs.uni-tuebingen.de/SNNS/>, é um simulador de Redes Neurais Artificiais criado na Universidade de Stuttgart, que proporciona um ambiente eficiente e flexível para auxiliar a criação, o treinamento e a manutenção das redes neurais artificiais. O simulador possui um grande número de algoritmos de aprendizado, e, entre esses, estão presentes diversas variações de *backpropagation* (CARVALHO, 2009).

Trata-se de um aplicativo desenvolvido a partir de 1989 e é um dos simuladores de redes neurais mais empregados pela comunidade científica, sendo executável em uma série de plataformas. No SNNS, a criação e edição das arquiteturas das redes são tarefas simples e rápidas. Também é possível acompanhar a evolução, tanto do erro de aprendizagem, quanto de validação, através de interfaces gráficas que o mesmo fornece. (ESPINHOSA, 2004).

Atualmente, o SNNS é mantido pela Universidade de Tübingen, instituição também responsável pelo desenvolvimento do seu sucessor. O JavaNNS foi desenvolvido baseando-se no SNNS, porém com uma nova interface gráfica implementada em Java. Assim, as aplicações do JavaNNS são muito semelhantes àsquelas possíveis com o SNNS, com a vantagem de uma interface gráfica mais fácil de ser entendida (FISCHER et al., 2001). Ainda, a configuração dos elementos de processamento são mais facilmente definidas e com a vantagem de edição das camadas separadamente.

O treinamento e a validação de redes neurais no JavaNNS são realizados a partir da apresentação de padrões de entrada/saída espacialmente correspondentes, definidos em um ou mais conjuntos de amostras. Segundo Galo (2000), a estrutura dos arquivos de treinamento e validação é definida de modo que cada padrão contemple a apresentação de vetores de entrada e saída, os quais são buscados sequencialmente na área selecionada para treinamento.



- **ENVI**

Trata-se de um software para visualização, exploração, análise e apresentação de dados na área de Sensoriamento Remoto/SIG. O ENVI foi desenvolvido a partir da linguagem IDL (Interactive Data Language). Isso lhe garante robustez, velocidade e sofisticação, sem necessitar de equipamento poderoso. A linguagem IDL, possui os mais avançados algoritmos para o tratamento espectral de dados. A nova versão, ENVI 4.8, apresenta ainda mais funcionalidades para tarefas de análise e processamento de dados espectrais (ENVI, 2011).

O aplicativo foi fundamental e utilizado em várias etapas do trabalho tais como: correção atmosférica, isolamento do corpo d'água, análise dos atributos espectrais das cenas e seleção das áreas de treinamento e validação para entrada na RNA.

- **IDRISI Andes**

O software IDRISI for Windows constitui-se de um Sistema de Informações Geográficas e de processamento de imagens desenvolvido pelo “Graduate School of Geography”, da “Clark University”, projetado para a análise de dados geográficos em formato matricial. Consiste de um programa principal de interface e mais de 150 módulos que fornecem facilidades da entrada, visualização e análise de dados geográficos. O IDRISI trabalha de forma analítica matriz (imagem), cobrindo um amplo espectro de necessidades de SIG (Sistema de Informação Geográfica) e de Sensoriamento Remoto, desde consulta a banco de dados e modelagem espacial, até realce e classificação de imagens (EASTMAN, 1998 apud ENNES, 2008).

Para esse trabalho, foi utilizado na geração da imagem dos dados de clorofila coletados em campo, na suavização das imagens World View-2 e na conversão dos arquivos de saída do JavaNNS em imagens com a distribuição espacial da variável de estudo.

- **ARCGIS**

Foi utilizado na confecção dos mapas apresentados no trabalho.



4.2. ABORDAGEM METODOLÓGICA

Como explicitado nos objetivos do trabalho, a inferência espacial da clorofila foi realizada a partir de uma rede neural artificial, com base em medidas pontuais da variável feitas por um fluorômetro de campo nos dias 17 e 18 de março de 2011 e uma imagem multiespectral tomada em 20 de março de 2011, a qual foi corrigida radiometricamente. Assim, os procedimentos executados se pautaram nos seguintes requisitos:

- Realização de campanha de campo complementada com a aquisição de uma imagem multiespectral, obtendo os valores de clorofila *a* em pontos de coordenadas conhecidas;
- Obtenção de medidas de reflectância *in situ*, utilizando um espectrorradiômetro de campo, visando conhecer o comportamento espectral da área estudada;
- Tratamento e análise da imagem multiespectral World View-2;
- Definição da arquitetura, dados de entrada e treinamento da RNA;
- Aplicação da rede treinada à imagem;
- Análise das representações geradas.

Nesse sentido, após a definição da área de estudos, as atividades desenvolvidas foram: planejamento da coleta de dados, campanha de campo, análise dos dados fluorimétricos e espectrorradiométricos, tratamento das imagens multiespectrais, treinamento da RNA, e inferência propriamente dita. A seqüência de execução dessas atividades é apresentada na Figura 21 e são descritas a seguir.






Figura 21 - Proposta metodológica do trabalho.

De acordo com a Figura 21, definida a área de estudo, efetuou-se o planejamento da campanha de campo, visto a necessidade de aquisição quase simultânea das medidas de concentração de clorofila e tomada da imagem multiespectral a ser utilizada. Nessa etapa, foram definidos os elementos amostrais nos quais foram efetuadas medidas espectralradiométricas e limnológicas.



As atividades realizadas na campanha de campo referem-se à coleta de dados nos elementos amostrais previamente definidos, que foram devidamente posicionados por meio de um receptor GPS, visando a identificação de suas coordenadas na imagem multiespectral. De modo geral, a obtenção de medidas de concentração de clorofila *a* deu-se remotamente, utilizando um fluorômetro de campo. Entretanto, ainda sim foi necessária a determinação laboratorial de clorofila *a* para os elementos amostrais, com o intuito de calibrar as medidas obtidas pelo instrumento citado.

Finalizando os procedimentos em campo, coletou-se dados espectrais dos elementos amostrais, utilizando um espectrorradiômetro de campo, o qual fornece a resposta espectral em termos de reflectância de superfície de cada elemento, possibilitando análises do comportamento espectral das águas do Cascata.

Nesse contexto, a imagem multiespectral, adquirida em data próxima à tomada de dados *in situ*, foi tratada efetuando-se a calibração radiométrica da cena, buscando a minimização da interferência da atmosfera, além de características inerentes ao sistema sensor. Ainda, com base na análise dos atributos espectrais das cenas foram executados procedimentos de suavização espectral da imagem, visando a geração de um produto mais adequado à inferência espacial.

Para a inferência geográfica da variável de interesse, foi utilizada uma RNA multicamadas. Foi feita a seleção dos dados de entrada, combinando as bandas espectrais da imagem original e suavizada. Ainda, selecionou-se as áreas de treinamento e validação e efetuou-se a preparação dos arquivos de padrões para iniciar o procedimento no simulador. Definida a arquitetura da rede e efetuando-se o treinamento, obtendo pesos e conexões ajustados, aplicou-se a rede à cena, possibilitando inferir a distribuição espacial da concentração de clorofila *a*.

Por fim, foi feita a conversão do resultado inferido pela rede em uma imagem que represente a distribuição espacial de clorofila no reservatório Cascata. Uma vez que os dados de entrada foram combinados de formas distintas, procedeu-se uma análise de qualidade das representações geradas.

Na Figura 21 estão destacadas em cores diferentes as principais vertentes metodológicas do trabalho. Nas seções seguintes é feita uma descrição minuciosa dos procedimentos e resultados obtidos com relação a cada uma dessas vertentes.



4.3. CARACTERIZAÇÃO ESPECTRAL DO RESERVATÓRIO CASCATA

Nessa etapa, objetivou-se efetuar uma caracterização espectral da área de estudos baseando-se em dados de reflectância de superfície. Tais dados foram submetidos a técnicas de processamento de dados espectralradiométricos buscando identificar as feições de absorção e espalhamento conhecidas da literatura e relacionadas à presença de componentes opticamente ativos, principalmente de clorofila *a*. Com isso, foi possível obter informações acerca do comportamento espectral das águas do reservatório Cascata e conseqüentemente indícios dos teores de componentes opticamente ativos desse ambiente.

A coleta dos dados espectralradiométricos foi realizada em duas campanhas de campo, a primeira delas em 06 de outubro de 2010 e a segunda em 17 de março de 2011.

Foi utilizado o espectralradiômetro FieldSpec Hand Held. Em cada elemento amostral, definidos por um esquema de amostragem aleatório, foram realizadas 10 medições do fator de reflectância de superfície da água, para o cálculo de uma curva de reflectância média. Antes de cada medição foi necessário calibrar o equipamento, utilizando uma placa de referência e realizar um procedimento de otimização, visando uma melhor acurácia das curvas espectrais obtidas para cada um dos elementos amostrais.

O software que realiza o processamento dos dados do instrumento fornece a opção de transformar o fator de reflectância medido em reflectância absoluta, assim, optou-se por utilizar medidas do valor de reflectância absoluta.

A primeira etapa no processamento dos dados foi calcular a média dos valores espectrais medidos para cada elemento amostral, a fim de gerar uma única curva espectral que representasse o elemento amostral. Definida a curva característica de cada elemento, aplicou-se uma técnica de suavização, já que dados obtidos sob condições naturais apresentam ruídos aleatórios de diversas naturezas que necessitam ser minimizados.

Utilizou-se um filtro de média móvel, considerado um filtro com bons resultados, sendo de implementação simples e baixo tempo computacional. Tsai e Philpot (1998) apresentam a formulação matemática desse filtro, citando que o mesmo calcula uma média dos valores espectrais de todos os pontos dentro de um intervalo discreto, com tamanho pré-especificado. Assim, o novo valor para o ponto médio da janela de suavização é calculado por:



$$\hat{s}(\lambda_j) = \frac{\sum s(\lambda_i)}{n} \quad (3)$$

Onde $\hat{s}(\lambda_j)$ é o espectro estimado livre de ruído; $s(\lambda_i)$ é o espectro original com ruído; n é numero de elementos considerados na janela e j é o índice de ponto central do filtro. Desse modo, efetuou-se a suavização com janelas de 3 e 7 pontos, visto que filtros de ordem superior podem provocar a remoção de feições espectrais de interesse.

Os dados de outubro de 2010 e março de 2011 foram suavizados com um filtro de janela de 3 e 7 pontos, respectivamente e as curvas de reflectância suavizadas dos elementos amostrais das duas campanhas de campo são apresentadas na Figura 22.




Figura 22 - Resposta espectral da água do reservatório Cascata.

A primeira diferença perceptível entre as curvas está relacionada aos máximos obtidos nas duas épocas. Nos dados de outubro de 2010 o máximo de reflectância é de 0,095, enquanto que para março de 2011 o pico de reflectância máxima é de 0,123.

Outro fato notável pela Figura 22 refere-se à grande amplitude de variação nos valores de reflectância das curvas de março de 2011. Exemplificando, há uma diferença de 4 vezes entre o maior e o menor valor em 568 nm. Possivelmente, as condições de iluminação instáveis durante o decorrer da campanha de campo podem ter prejudicado a coleta de curvas espectrais. Ainda assim, prosseguiu-se a análise de tal conjunto de dados, buscando indícios da presença de COAs.

Percebe-se que as curvas espectrais de outubro de 2010 apresentam feições de forma e magnitude muito semelhantes. A resposta espectral da água nessa amostragem é bastante similar à apresentada por Bukata et al. (2005) para águas com pequena concentração de clorofila *a* e gradativo acréscimo de MOD, que tende a diminuir a resposta da água em



todos os comprimentos de onda. A correspondência com a literatura é verificada principalmente para os primeiros comprimentos de onda (verde e azul).

Desse conjunto de dados, dois pontos apresentam uma feição próxima à 600 nm que pode ser considerado um indício da presença do pigmento fotossintetizante ficocianina. Ruiz-Verdú et al. (2008) demonstram que a ficocianina introduz uma feição semelhante à apresentada na Figura 22, entretanto em aproximadamente 615 nm. Desse modo, a presença de tal componente deve ser avaliada em detalhes, uma vez que pode indicar a presença de cianobactérias no ambiente, sendo que desse grupo vegetal, algumas espécies são tóxicas.

As curvas de reflectância de março de 2011 também apresentam uma feição em 600 nm que, mais uma vez, podem estar ligadas à presença de ficocianina. Os picos de absorção e reflectância em aproximadamente 670 e 700 nm mantiveram-se bem definidos, assim como nas curvas de 2010. Tais feições são fortes indícios da presença de clorofila *a*, como discutido na Fundamentação Teórica.

Outra constatação quanto às curvas de 2011 diz respeito ao pico de reflectância na região espectral do verde. Percebe-se que essa feição não está bem definida como um pico, apresentando um patamar entre 535 a 580 nm. Assim, a resposta espectral da água em março de 2011 se assemelha à resposta causada por água contendo algas e sedimentos em suspensão, como descreve Han (1997 apud JENSEN, 2009). Entretanto, deve-se ressaltar que as curvas obtidas nessa campanha de campo foram fortemente degradadas devido às variações nas condições de iluminação.

De qualquer modo, percebe-se a complexidade do ambiente estudado, visto que a resposta espectral do mesmo é a soma de várias componentes. Visando verificar a possível influência dos componentes opticamente ativos à resposta espectral da água, foi aplicada a técnica de análise derivativa nas curvas espectrais.

Conceitualmente, a aplicação de uma operação de derivada sobre uma função, representa uma forma de quantificar a taxa de variação de uma determinada variável em relação à outra. No caso de um espectro, representa a taxa de variação de reflectância espectral do alvo em relação à variação do comprimento de onda da energia incidente (BARBOSA, C., 2005).

Para o cálculo das derivadas de curvas espectrais, Tsai e Philpot (1998) recomendam a utilização da aproximação por diferença finita, na qual o resultado da aproximação depende da resolução espectral (separação entre as bandas) e o tamanho do filtro



ou da largura da banda. A equação (4) mostra como pode ser estimada a primeira derivada de uma curva espectral:

$$\left. \frac{ds}{d\lambda} \right|_i \approx \frac{s(\lambda_i) - s(\lambda_j)}{\Delta\lambda} \quad (4)$$

Em que $\Delta\lambda$ é a separação entre as bandas adjacentes; sendo $\lambda_j > \lambda_i$, com o intervalo entre as bandas constante; $s(\lambda_i)$, $s(\lambda_j)$, são valores do espectro na faixa dos comprimentos de ondas λ_i e λ_j , respectivamente. A segunda derivada pode ser obtida pela derivada da primeira apresentada na Equação (5);

$$\left. \frac{d^2s}{d\lambda^2} \right|_j = \frac{d}{d\lambda} \left(\left. \frac{ds}{d\lambda} \right|_j \right) \approx \frac{s(\lambda_i) - 2s(\lambda_j) + s(\lambda_k)}{(\Delta\lambda)^2} \quad (5)$$

Onde $\Delta\lambda = \lambda_k - \lambda_j = \lambda_j - \lambda_i$; $\lambda_k > \lambda_j > \lambda_i$.

No presente trabalho, esse procedimento foi efetuado no aplicativo Microsoft Excel, no intuito de distinguir as feições descritas na literatura relacionadas à componentes opticamente ativos. O resultado da aplicação de derivadas nas curvas de outubro de 2010 e março de 2011 é apresentado na Figura 23.






Figura 23 - Espectros de reflectância originais, derivadas de primeira e segunda ordem.

Para a primeira derivada, os locais de cruzamento com o eixo das abscissas (valor nulo na ordenada) correspondem aos maiores picos de absorção ou espalhamento da reflectância original e os picos encontrados nas curvas de primeira ordem salientam as regiões espectrais de maior inclinação da curva de reflectância original. Na Figura 23, observa-se que, de um modo geral, as curvas tendem a formar um ponto de cruzamento no eixo das abscissas, em aproximadamente 576 nm para os dados de 2010 e em 550 nm para os dados de 2011, correspondentes aos respectivos picos de maior valor de reflectância no espectro original na região do verde.

Comparando-se as curvas de primeira derivada àquelas obtidas por Goodin et al. (1993), percebe-se que as mesmas apresentam o padrão de pico e vale alternados entre 670 a 750 nm como o observado na literatura. Embora o pico definido em 670 nm seja característico



da presença de clorofila (região de máxima absorção do pigmento), a feição de absorção em 720 nm ocorre tanto na presença de clorofila, quanto na presença de sólidos em suspensão, sendo considerada menos efetiva para discriminar os efeitos ocasionados por esses dois componentes.

Entretanto, os autores ressaltam que obtiveram um alto coeficiente de correlação ($r = -0,95$; $p < 0,0001$) entre o valor absoluto da primeira derivada em 720nm e a concentração de sólidos em suspensão e citam que o valor absoluto dessa feição é proporcional à concentração de TSS. Para os dois conjuntos de dados estudados, percebe-se que não há variação significativa na magnitude dessa feição, indicando valores homogêneos de TSS, como também elucidado pelos valores de turbidez apresentados na Caracterização Limnológica Básica do Reservatório Cascata (seção 3.2).

De acordo com Goodin et al. (1993), a segunda derivada é considerada útil na avaliação dos efeitos de clorofila, uma vez que os efeitos de sedimentos em suspensão são eliminados na primeira derivada. Na presente pesquisa percebe-se que as curvas espectrais de outubro de 2010 apresentaram comportamento ruidoso, mesmo após a suavização das curvas. Para os dados de março de 2011, as feições foram sutilmente melhor definidas, embora não sejam compatíveis com as apresentadas na literatura.

Desse modo, a análise das curvas espectrais do reservatório Cascata mostrou que se trata de um ambiente com características de água com pequenas concentrações de clorofila *a*, sedimentos em suspensão e material orgânico dissolvido.

Com relação à análise derivativa, deve-se ressaltar que os estudos buscados como referência na literatura, de modo geral apresentam duas características importantes: (1) são conduzidos sob condições controladas e (2) dedicam-se a analisar ambientes com elevadas concentrações de componentes opticamente ativos, analisando separadamente cada componente, ou com grandes discrepâncias nos valores (pequenos valores de turbidez e elevados valores de clorofila e vice-versa). A realidade encontrada nesse estudo é diferente, portanto, deve-se considerar a adequação das técnicas ou emprego de outras técnicas para dados com baixas concentrações de COAs e para casos em que os mesmos co-existam em níveis semelhantes.

Nesse sentido, alguns autores sugerem o uso de técnicas que focam a região de fluorescência da clorofila localizada entre a luz vermelha e o IVP. A Altura da Linha de Fluorescência (Fluorescence Line Height - FLH) pode ser calculada a partir de espectros de



radiância ascendente, como fizeram Gitelson et al. (1994) e obtiveram resultados satisfatórios na modelagem de clorofila *a* para um ambiente que apresenta baixos teores dessa variável. Outros autores, como Yacobi et al. (1995) também utilizaram essa abordagem com sucesso e Giteslon et al. (2000) afirmam que em ambientes com concentrações de clorofila inferiores a 20 µg/L o pico de fluorescência em 685 nm é a melhor feição espectral para estimativa do pigmento através de dados de sensoriamento remoto.

4.4. CONCENTRAÇÃO DE CLOROFILA A POR FLUORIMETRIA DE CAMPO

A aquisição de dados de clorofila *a* utilizando um fluorômetro de campo é fundamental para a obtenção de um conjunto de dados adequado para a utilização de RNA na inferência espacial, uma vez que é necessária a divisão da amostra em elementos para treinamento e validação. Este instrumento opera em fluxo contínuo e remotamente, reduzindo significativamente custos de ordem técnica e financeira.

Foram efetuadas duas coletas de dados fluorimétricos durante a execução do trabalho, utilizando o fluorômetro de campo 10-AU. A primeira delas, ocorrida em 06 de outubro de 2010, buscou o reconhecimento do recurso hídrico e treinamento com o instrumento de campo, já a segunda coleta, realizada nos dias 17 e 18 de março de 2011, foi a que forneceu efetivamente os dados de clorofila *a* necessários ao desenvolvimento geral da pesquisa.

De acordo com a fabricante, o fluorômetro 10-AU pode ser utilizado para mapeamento ou monitoramento de clorofila *in loco*. Como a fluorescência é uma medida relativa - a intensidade de fluorescência é diretamente proporcional a concentração de fluoróforo (HOLLER et al., 2009) - é necessário que as medidas do fluorômetro sejam calibradas a partir de elementos amostrais cuja determinação do pigmento seja feita por um método laboratorial reconhecido, possibilitando obter a real concentração de clorofila *a* (TURNER DESIGNS, 1999).

Segundo a empresa, existem duas maneiras de estimar a concentração dos pigmentos, normalmente utiliza-se o método padrão primário, cujos dados *in vivo* coletados com o fluorômetro são normalmente calibrados correlacionando-os com concentrações de



pigmentos de amostras extraídas em campo ou em ambientes controlados com posterior análise em laboratório. O fluorômetro pode então ser configurado para registrar o pigmento em análise, mas deve estar claro que mudanças nas condições do ambiente podem introduzir mudanças significativas na leitura mesmo ocorrendo no mesmo dia.

Desse modo, a campanha de campo efetuada nos dias 17 e 18 março de 2011 objetivou também a aquisição de medidas para calibração do instrumento. No primeiro dia foi feito um levantamento amostral pontual, no qual alíquotas de água foram coletadas para posterior determinação laboratorial de clorofila *a* simultânea à aquisição de medidas com o fluorômetro. Os pontos foram definidos a partir de um esquema de amostragem aleatório, e foram devidamente posicionados utilizando um receptor GNSS Hiper GGD. O método de levantamento utilizado foi o *Stop-and-Go*, ou relativo semi-cinemático. Um receptor base foi posicionado às margens do reservatório, sendo que este teve suas coordenadas definidas pelo posicionamento relativo estático. A seguir, são apresentados os elementos amostrais utilizados para determinação laboratorial de clorofila (Figura 24).



Figura 24 - Elementos amostrais com determinação laboratorial de clorofila *a*.

As alíquotas de água coletadas nos pontos da Figura 24 foram armazenadas em baixa temperatura para posterior determinação da concentração de clorofila *a* utilizando técnicas de cromatografia líquida de alta resolução (HPLC) no laboratório do Núcleo de Pesquisas Avançadas em Matologia da Unesp de Botucatu (NUPAM/FCA). As amostras foram submetidas à homogeneização por 2 minutos no homogeneizador em potência máxima, submetidos a ciclo de ultrasonicação por 30 minutos, então filtradas em filtros de 0.22 µm para se submeter a análise do HPLC (ROMBOLA, 2001).

A determinação da clorofila foi realizada através de um equipamento de HPLC, com detector de fluorescência (SHIMADZU), e comprimentos de onda de excitação em 440 nm e emissão em 680 nm, sendo capaz de se detectar em concentrações precisas de clorofila na amostra (ROMBOLA, 2011).

A determinação da concentração de clorofila *a* nos elementos amostrais foi necessária para construção da curva de calibração e conseqüente ajuste das leituras do fluorômetro de campo. Para a construção da curva foram utilizados 8 elementos amostrais, garantindo um bom ajuste da reta. Tais pontos contemplaram a faixa predominante de leituras de fluorescência, assim a reta de regressão utilizada na calibração foi modelada de acordo com as características reais dos dados de campo. O modelo estimado para o ajuste é apresentado na Figura 25.




Figura 25 - Curva de calibração dos dados de campo baseada nas análises laboratoriais.

A regressão resultou na equação $[Chl-a] = 0.3501 * F$. A correlação, e conseqüentemente o coeficiente de determinação, obtidos apresentaram valores satisfatórios



($r=0.8915$ e $R^2=0.7925$, respectivamente), possibilitando a atualização dos valores de concentração de clorofila *a* das leituras do fluorômetro obtidas em fluxo contínuo no dia 18/03/2011.

Como mencionado, a coleta em fluxo contínuo foi efetuada no dia 18 de março de 2011. O trajeto de coleta foi registrado com o auxílio do receptor GNSS, dessa vez realizou-se o posicionamento relativo cinemático, utilizando como base o mesmo ponto utilizado no posicionamento *Stop-and-Go*. Para que fosse possível a sincronização das medidas de fluorescência e as coordenadas dos pontos, os dois equipamentos tiveram suas taxas de coletas definidas como 5 segundos e foram ligados simultaneamente. A defasagem temporal entre os dois foi de 2 segundos e foi considerada aceitável, assim, com a calibração dos dados do fluorômetro de campo e sincronização com as coordenadas UTM, obteve-se uma amostragem densa na área de estudos a respeito da concentração real de clorofila *a*, a qual pode ser visualizada na Figura 26. Ao total obteve-se 728 observações de clorofila *a* através desse método de amostragem.



Figura 26 - Visualização do trajeto de coleta de dados fluorométricos.

Apenas com a finalidade de comparação, a reta de regressão definida para calibração das medidas fluorimétricas de março de 2011 também foi aplicada aos dados da campanha de campo de outubro de 2010. A estatística descritiva básica dos dados é apresentada na Tabela 1.

Tabela 1 - Estatística básica das amostragens fluorimétricas de 2010 e 2011.

	Outubro de 2010	Março de 2011
Valor mínimo	0,93	1,57
Valor máximo	10,75	5,22
Média	4,68	2,36
Desvio-padrão	2,01	0,41

Os valores de clorofila *a* obtidos em outubro de 2010 e ajustados pela curva de calibração construída apresentaram maiores valores comparando-se com os coletados em 2011. A concentração média em 2010 foi de 4,68 µg/L e caiu para 2,36 µg/L em 2011. Portanto, nota-se que os valores para a campanha exploratória foram superiores e com maior variação (desvios padrão de 2,01 e 0,41 para 2010 e 2011, respectivamente) em relação aos obtidos na campanha cujo objetivo foi a efetiva aquisição de dados para a posterior espacialização da variável clorofila *a*, fato que a análise visual prévia do ambiente estudado indicou.

Nesse contexto, de maneira contrária às observações apresentadas em anos anteriores e relatadas no Relatório de Qualidade das Águas do Estado de São Paulo, que indicam altos teores de clorofila *a* nas águas do reservatório Cascata durante todos os períodos do ano, as campanhas de campo evidenciaram outra realidade, apresentando valores de baixa concentração.

4.5. TRATAMENTO DA IMAGEM MULTIESPECTRAL PARA DETECÇÃO DE CLOROFILA

Para que seja possível correlacionar medidas de variáveis biofísicas coletadas *in situ* de alvos altamente dinâmicos com imagens de sensoriamento remoto, é necessária



correspondência temporal nas coletas realizadas em nível terrestre e orbital. Assim, se o intuito é realizar inferência de um parâmetro limnológico a partir de imagens, deve-se prezar pela compatibilidade das datas das duas coletas.

A imagem multiespectral World View-2 foi tomada no dia 20 de março de 2011. Nesse caso, a defasagem temporal com a campanha de campo foi de dois dias. Visto que não houve nenhuma alteração meteorológica brusca, ou intervenções diretas no recurso hídrico que pudessem alterar significativamente as características limnológicas do mesmo, essa defasagem foi considerada aceitável.

A imagem foi adquirida no nível de processamento 2A, ou *Ortho Ready Standard Imagery*. Trata-se de uma imagem com nível básico de correção geométrica e radiométrica, incluindo correções de erros inerentes aos sensores e relacionando-a a um sistema de referência.

Como já explicitado anteriormente, para o relacionamento de imagens multiespectrais com variáveis biofísicas, é fundamental a correção atmosférica da cena. No presente trabalho a correção atmosférica foi efetuada no *software* ENVI 4.8, utilizando o módulo FLAASH.

Primeiramente, foi efetuada a calibração dos valores de radiância da cena World View-2. ITT (2010) cita que as imagens desse sensor são fornecidas aos usuários em valores de radiância relativa, assim, o primeiro processamento aplicado às bandas espectrais da imagem foi a calibração radiométrica, resultando em valores de radiância absoluta no sensor. O procedimento para essa calibração é descrito em Updike e Comp (2010), e também está implementado no ENVI.

Desse modo, prosseguiu-se à correção atmosférica. Para isso, o módulo FLAASH solicita parâmetros da geometria de aquisição da cena (coordenadas do centro da cena, altitude do sensor, altitude média do terreno, data de aquisição, hora GMT, resolução espacial e ângulo zenital do sensor, se o mesmo não possui visada nadir), os quais são extraídos dos arquivos metadados da imagem. Com relação aos parâmetros atmosféricos, são solicitados: modelo atmosférico e, em função disso, parâmetros de concentração de vapor d'água, modelo de aerossóis e visibilidade.

O modelo atmosférico foi definido como tropical, visto que essa é a região geográfica da área de estudos, o parâmetro de concentração d'água foi baseado no valor padrão para um modelo tropical, com o acréscimo de um fator multiplicador que foi



determinado a partir do produto MOD07_L2 do sensor MODIS/TERRA, cujos dados foram coletados simultaneamente à aquisição da imagem World View-2.

O modelo de aerossóis foi definido como urbano, já que o reservatório se localiza na zona urbana do município de Marília e o valor de visibilidade foi definido empiricamente, como sugere Ennes (2008), que cita a necessidade de, inicialmente, estimar o parâmetro visibilidade e depois reajustá-lo, até que os espectros de reflectância resultantes do modelo sejam compatíveis com o comportamento espectral esperado para os alvos.

Desse modo, buscou-se um resultado cujos atributos dos pixels estivessem dentro de um limite aceitável de uma imagem de reflectância (0 a 10000, já que se utilizou um fator multiplicativo de 10^4) e que os alvos mantivessem seu comportamento espectral inalterado. Assim, como definido em Ennes (2008), foram avaliadas as respostas espectrais de alvos como água e vegetação após as tentativas de correção. Nesse caso, o valor de visibilidade mais adequado foi de 100 km, o que caracteriza uma atmosfera sem neblina. A Figura 27 mostra um perfil espectral de um ponto no reservatório extraído da imagem original e corrigida, para exemplificar a análise feita.




Figura 27 - Perfil espectral de um ponto do reservatório Cascata. Dados originais (a) e corrigidos (b).

Pela Figura 27, percebe-se que de modo geral, a forma do perfil manteve-se semelhante, com exceção à primeira banda espectral. Percebe-se que o valor de reflectância (27b) na banda 1 foi reduzido a um valor inferior ao encontrado na banda 2, o que não acontece no perfil original (27a). Esse é um primeiro indício da remoção do efeito



atmosférico, já que os primeiros comprimentos de onda do espectro visível são os mais afetados pela atmosfera. Ainda, percebe-se que o alvo teve uma resposta esperada também nos maiores comprimentos de onda do espectro, onde a água absorve praticamente toda a radiação, apresentando um valor de reflectância quase nulo.

Com base no exposto anteriormente, e no fato de que os demais pixels analisados apresentaram-se consistentes, o resultado da correção atmosférica foi considerado satisfatório.

Vale ressaltar que durante os testes de valores de visibilidade pôde-se perceber pixels com valores negativos em todas as bandas espectrais. Com relação a esses valores, sua ocorrência foi minimizada, mas para algumas bandas, não foi totalmente removida. Veloso (2009) efetuou a correção atmosférica de imagens ASTER e também identificou esse problema. Segundo o autor, trata-se de uma limitação do algoritmo implementado no FLAASH ao processar determinadas imagens ASTER. Essa falha se manifesta de maneira aleatória, na forma de valores negativos de reflectância de superfície, da mesma forma que foi observada para a imagem World View-2 utilizada nesta pesquisa. Tais pixels não se localizaram no reservatório Cascata, não comprometendo os processamentos seguintes.

Além disso, deve-se advertir que o ideal é a obtenção direta dos parâmetros atmosféricos necessários aos modelos, mas isso raramente ocorre. Assim, a alternativa encontrada nesse trabalho, foi utilizar dados MODIS para estimativa de vapor d'água e valores empíricos para visibilidade, bem como realizar uma análise dos alvos, o que se mostrou uma boa opção para correção de cenas World View-2.

Depois de efetuada a correção atmosférica da cena, procedeu-se o isolamento do alvo de interesse, no caso, o reservatório Cascata. Isso para que fosse possível analisar separadamente seus atributos espectrais e posterior modelagem ambiental de clorofila *a*. O recorte do corpo d'água foi realizado no aplicativo ENVI utilizando o resultado de uma segmentação espectral da banda 7 (na região IVP, na qual a ausência de resposta espectral da água permite diferenciá-la dos demais alvos), cuja máscara foi usada para extrair os valores de reflectância de superfície apenas no interior do corpo d'água, em cada banda espectral.

Com a delimitação espacial do alvo, as etapas seguintes visaram explorar seus atributos espectrais. Desse modo, embora a cena apresente 8 bandas espectrais, apenas 7 foram utilizadas no estudo, já que a região espectral da banda NIR2 (860 - 1040 nm) não é uma região adequada a estudos espectrais da água, uma vez que este alvo absorve toda a radiação eletromagnética incidente. Os indicadores estatísticos do reservatório Cascata com e



sem correção atmosférica nas 7 bandas espectrais são apresentados na Tabela 2. A Figura 28, por sua vez, mostra os valores médios de ND e reflectância para cada banda espectral da área de estudos.

Tabela 2 - Estatística básica dos atributos espectrais do reservatório Cascata.

Bandas	ND		R. de superfície(*10 ⁴)	
	Média	Desv. Padrão	Média	Desv. Padrão
B1 - Costal	334,6565	9,62813761	394,547021	66,2251152
B2 - Azul	247,67953	10,3307934	388,859862	58,0216529
B3 - Verde	264,39189	14,7204352	428,036536	47,8276317
B4 - Amarelo	183,58646	16,8027768	375,711335	55,6964486
B5 - Vermelho	105,92762	14,5465147	283,270119	62,5361813
B6 - Vermelho limítrofe	125,98648	28,2600614	305,733953	92,5248883
B7 - Infra vermelho próximo 1	91,410401	35,1614578	204,278389	103,171633

Comparando-se os números digitais e os valores de reflectância médios em cada banda, percebe-se que apresentam o mesmo comportamento, reduzindo seus valores da banda 1 para a banda 2, em seguida aumentando na banda 3, diminuindo novamente na banda 4 e assim por diante. Entretanto a variação dos valores de reflectância de superfície das bandas 1 e 2 foi consideravelmente menor (Figura 28) reforçando, mais uma vez, a capacidade do algoritmo de remover os efeitos atmosféricos dos menores comprimentos de onda do espectro visível. Já o desvio padrão não seguiu o mesmo comportamento, o que pode indicar que, com a minimização dos efeitos atmosféricos, a combinação dos diferentes COAs provoca alterações distintas ao longo do espectro eletromagnético nos pixels da imagem.






Figura 28 - Média dos ND (a) e reflectância de superfície (b) registrados pelo sensor World View-2 para a área de estudos.

Prosseguindo na análise da imagem multiespectral, foi feita uma inspeção visual no aspecto do reservatório Cascata em cada uma das bandas espectrais. Verificou-se um efeito salpicado em todo o reservatório que, levando em consideração o fato de que alterações significantes na resposta espectral de um pequeno corpo d'água dificilmente ocorrem de maneira brusca e visto que a resolução espacial da imagem é de 2 metros, considerou-se que tal efeito pode não estar associado ao comportamento da água em si.

Nesse sentido, a utilização de técnicas de filtragem para remover o efeito dessa variação espectral, visto que esta não representa a real interação da REM na coluna d'água, foi a opção encontrada para adequar a utilização de tais imagens à inferência de clorofila. Segundo Novo (2008), uma filtragem é uma operação no domínio espacial da imagem que consiste no uso de uma “janela móvel” que se desloca sobre a imagem e executa determinadas operações sobre os pixels nela contidos. Desse modo, o valor registrado para o pixel central da janela é o resultado da sua combinação com os valores de seus vizinhos.

Para suavização de imagens, é normalmente usado filtros passa-baixa, os quais preservam os componentes de baixa frequência de uma imagem, suavizando-a. Richards e Jia (2006) destacam os filtros passa-baixa baseados na média e na mediana da janela móvel como os principais métodos de suavização. Enquanto um filtro média suaviza a imagem de modo geral, podendo remover bordas, o filtro mediana conserva, podendo até realçar, essa informação. Nesse sentido, efetuou-se uma suavização utilizando os dois tipos de filtros, ambos de janelas de 3 x 3 pixels, cujos resultados são apresentados na Figura 29.






Figura 29 - Comparação entre a imagem de reflectância original (a), suavizada com filtro média (b) e suavizada com filtro mediana (c). Composição 5R-3G-2B.

A Figura 29a apresenta a imagem de reflectância em seu aspecto original, na qual se percebe um aspecto granuloso devido à variação intensa nos valores registrados na imagem. A suavização com um filtro média (Figura 29b) proporcionou uma representação que reduziu o efeito salpicado sem mascarar as variações de reflectância no ambiente aquático, enquanto que a utilização de um filtro mediana, que tende a preservar bordas nas imagens, resultou em uma imagem com padrão ondulado (Figura 29c). Com isso, considerou-se que as imagens suavizadas com um filtro média apresentaram resultados mais adequados à representação das variações espectrais no corpo d'água e, juntamente com as imagens originais, foram utilizadas na inferência espacial de clorofila *a*.

4.6. INFERÊNCIA GEOGRÁFICA DE CLOROFILA *A* UTILIZANDO REDES NEURAIS ARTIFICIAIS

Para dar-se início ao processo de inferência geográfica de clorofila *a* é necessário a definição dos dados de entrada e de saída que serão apresentados à rede. Assim, foram considerados como dados de entrada as bandas espectrais do sensor World View-2 nas quais a presença de clorofila pode alterar a resposta espectral da água. Foram utilizadas as bandas com valor de reflectância de superfície original e as bandas suavizadas com um filtro média.

Cada um dos conjuntos de bandas foram combinadas de três formas distintas, possibilitando a criação de seis conjuntos de dados de entrada, que são apresentados no Quadro 2.

Combinação	Bandas Originais ¹	Combinação	Bandas Suavizadas
1 – <i>org_tds</i>	1, 2, 3, 4, 5, 6, 7	4 – <i>svz_tds</i>	1, 2, 3, 4, 5, 6, 7
2 – <i>org_356</i>	3, 5, 6	5 – <i>svz_356</i>	3, 5, 6
3 – <i>org_36</i>	3, 6	6 – <i>svz_36</i>	3, 6

Quadro 2 - Combinação dos dados de entrada para o JavaNNS.

Os três primeiros conjuntos (1, 2 e 3) são combinações das bandas espectrais apenas submetidas ao procedimento de correção atmosférica (denominados com o prefixo *org*), e os conjuntos 4, 5 e 6 constituem-se arranjos entre as bandas espectrais suavizadas (cujos nomes se iniciam em *svz*). As combinações entre o conjunto de bandas originais e suavizadas foi feita de maneira análoga, sendo que a primeira combinação utilizou as 7 bandas onde a água apresenta resposta espectral (bandas de 1 a 7) e foi utilizada para avaliar a contribuição de valores de reflectância ao longo de todo o espectro, na modelagem espacial de clorofila (combinações 1- *org_tds* e 4 - *svz_tds*). O segundo tipo de combinação efetuada buscou utilizar as bandas cujos comprimentos de onda são fortemente influenciados pela presença de clorofila, seja apresentando feições de espalhamento – onde localizam-se as bandas do verde e vermelho limítrofe, seja apresentando feições de absorção, como é o caso da região da luz vermelha (combinações 2 - *org_356* e 5 - *svz_356*). A terceira combinação teve como objetivo selecionar as regiões com os dois maiores picos de reflectância, e que possuem contribuição do teor de clorofila *a* para definição de sua magnitude, ou seja, as bandas 3 (verde) e 6 (vermelho limítrofe), gerando as combinações 3 - *org_36* e 6 - *svz_36*.

Como o intuito é a inferência de clorofila *a*, os dados de saída referem-se à valores pontuais da concentração do pigmento no corpo d'água. A geração da imagem com valores de clorofila *a* foi efetuada no *software* IDRISI Andes, utilizando-se os parâmetros da cena World View-2 e convertendo os valores de clorofila de um arquivo vetorial para o

¹ Como apresentado no Quadro 1(p. 50): Banda 1 - Costal; Banda 2 - Azul; Banda 3 - Verde; Banda 4 - Amarelo; Banda 5 - Vermelho; Banda 6 - Vermelho limítrofe; Banda 7 – IVP1.



formato matricial. Desse modo, os dados de entrada (imagem) e saída (concentração de clorofila) da rede neural são espacialmente correspondentes.

Selecionados os dados de entrada e saída da rede, a etapa seguinte foi a definição dos conjuntos de treinamento e validação. Como cita Zell et al. (1995), a capacidade de generalização de redes neurais configura uma de suas maiores vantagens e, para obter melhor generalização, os autores recomendam que a base de dados seja dividida em três partes:

- Conjunto de treinamento: empregado para o aprendizado da rede neural. O erro da base de dados é minimizado durante o treinamento;
- Conjunto de validação: usado para estimar o desempenho da rede neural sobre o conjunto de padrões que não foram treinados durante a aprendizagem.
- Conjunto de teste: utilizado para checar o desempenho global da rede, que na realidade, é o conjunto de dados ao qual a rede treinada será aplicada.

Nesse sentido, foram definidos os conjuntos de treinamento e validação já que, para a inferência espacial, o conjunto de teste é toda a cena. Os dois conjuntos foram selecionados a partir do levantamento amostral em fluxo contínuo de clorofila *a*. O intuito foi relacionar áreas com densa amostragem da variável e que contemplasse as variações na concentração do pigmento. Os principais parâmetros dos conjuntos selecionados são apresentados na Tabela 3.

Tabela 3 - Estatística descritiva dos conjuntos de treinamento e validação.

	Treinamento	Validação
Valor mínimo	1,568	1,603
Valor máximo	3,781	3,077
Média	2,613	2,290
Desvio padrão	0,312	0,344
Número de elementos	282	260

Obteve-se então um conjunto de 282 elementos amostrais de clorofila *a* para treinamento e 260 elementos amostrais para validação. Como o conjunto de dados coletados



com o fluorômetro totaliza 728 observações, restaram ainda 186 elementos pontuais para analisar a qualidade da representação gerada. Percebe-se que tanto para os dados de treinamento, quanto de validação os valores de clorofila *a* variam pouco ao redor da média, apresentando um desvio padrão de aproximadamente 0,3, embora a diferença entre o valor máximo e mínimo seja de aproximadamente 2,2 e 1,5 para os dados de treinamento e validação, respectivamente. Nesse sentido, embora os valores extremos não possam ser considerados representativos na amostra, optou-se por não suprimi-los para que a rede neural artificial tenha sua capacidade de generalização aprimorada, uma vez que somente a utilização de valores médios pode resultar em uma representação variabilidade ainda menor.

Para utilizar o JavaNNS, assim como o SNNS, é necessário converter os dados para um formato de arquivo que o simulador reconheça. Esse formato (“.pat”) define um arquivo de padrões, composto por um cabeçalho e um componente de dados. O cabeçalho estabelece quantos padrões o arquivo contém, assim como a dimensionalidade dos vetores de entrada e classes de saída. O componente de dados é simplesmente uma lista de números que indica os atributos de entrada e de saída. Para cada padrão, o número de valores listados deve corresponder ao número de elementos de processamento da primeira camada da rede, acrescido do número de unidades de saída, conforme definido no cabeçalho (ZELL et al., 1995).

Assim, definidas as áreas de treinamento e validação foi necessária a criação dos arquivos de padrões. Para isso, foi implementado um programa computacional² que permite montar esses arquivos de padrões segundo a estrutura anterior, a partir dos dados de entrada e saída necessários em formato ASCII.

De posse dos dados de treinamento e validação em formato compatível, foi determinada a arquitetura da rede neural. Por definição, o número de elementos de processamento (EPs) da camada de entrada é correspondente ao número de *layers* de entrada. A camada de saída corresponde ao número de respostas esperadas, no caso de inferência de modo geral, é apenas uma. A arquitetura da rede foi testada diversas vezes para cada uma das combinações dos dados de entrada, com uma e duas camadas escondidas, com número de nós variáveis.

O real processamento de informações dentro dos EPs no JavaNNS é modelada com uma função de ativação e uma função de saída. Primeiramente, a função de ativação

² Programa desenvolvido pelo Prof. Dr. Maurício Galo, Departamento de Cartografia, FCT/Unesp.



calcula a entrada líquida da unidade a partir da ponderação dos valores de saída das unidades anteriores. Em seguida, calcula a nova ativação desta entrada, utilizando a função selecionada propriamente dita, e a função de saída leva este resultado para gerar a saída da unidade, que servirá de entrada para os EPs da camada seguinte (ZELL et al., 1995).

No JavaNNS é possível editar as funções de ativação de cada *layer*, proporcionando maior controle do usuário na definição da topologia da rede. Para este trabalho, seguindo as orientações de Osório (2006), os EPs da camada de entrada apresentam uma função de ativação do tipo identidade, nas camadas escondidas a função de ativação dos EPs é do tipo sigmóide (*act_logistic*), e na camada de saída a função de ativação foi definida como *act_identityplusbias* que adiciona uma componente de ganho ao valor de entrada na função, fornecendo valores reais da variável inferida. O autor cita essa configuração como sendo adequada para tarefas de aproximação/regressão, como é o caso deste trabalho.

As funções de saída dos EPs em todos os *layers* foram definidas como função identidade, para manter o valor processado pela função de ativação como resultado do processamento naquele EP. Tal configuração dos EPs em cada uma das camadas foi mantida para todas as arquiteturas testadas.

A maneira como a rede aprende que uma entrada específica corresponde a um dado valor de saída está relacionada com o treinamento da rede. Portanto, é através do comportamento de uma rede neural durante a fase de treinamento que se pode avaliar sua adequação para a categorização dos dados disponíveis. Isso significa que, além da arquitetura da rede (definida pelo número de camadas escondidas e número de nós em cada camada), devem ser estabelecidos os parâmetros relacionados com as funções de aprendizagem e com as regras estabelecidas para a atualização de pesos e inicialização da rede, além do critério de término do treinamento adotado, para um conjunto específico de dados de entrada (GALO, 2000).

O algoritmo de treinamento comumente utilizado é o *backpropagation*, cuja concepção se baseia na Regra Delta Generalizada. Essa regra procura minimizar o erro obtido pela rede por meio do método do gradiente decrescente. O objetivo desse gradiente é buscar um mínimo global, sendo que, o mínimo global é considerado como uma solução teórica ótima, pois apresenta o menor erro possível (SANTOS, 2001).

Uma variação desse algoritmo tem sido frequentemente utilizada para estudos de inferência geográfica, trata-se do algoritmo *Relisient Backpropagation*, ou RPROP



(MOREIRA, 2001; SAMIZAVA et al., 2007). O RPROP é um esquema de aprendizado de adaptação local, que necessita da definição de três parâmetros: o valor de atualização inicial (Δ_0), um limite máximo de atualização ($\Delta_{\max}$) e o expoente de decaimento do peso (α) (ZELL et al., 1995).

O primeiro, como o próprio nome diz, é um valor inicial, a partir do qual os pesos começarão a ser ajustados. O limite máximo de atualização tem como função prevenir que os pesos se alterem bruscamente e o expoente de decaimento do peso visa diminuir o valor do peso, o que resultaria numa melhor generalização (MOREIRA, 2001).

O algoritmo de treinamento, bem como os parâmetros do mesmo foram definidos baseando-se em Zell et al. (1995), Moreira (2001) e Samizava et al. (2007). Utilizou-se o RPROP como algoritmo de treinamento, Δ_0 igual a 0.1, $\Delta_{\max}$ sendo igual a 40 e o valor de α igual a 4. Alguns testes foram feitos utilizando $\Delta_{\max}=50$ e $\alpha=5$, a partir dos quais verificou-se que a alteração em $\Delta_{\max}$ não causou alterações significativas no resultado, enquanto que a alteração de α prejudicou consideravelmente as representações geradas.

Outro componente importante do treinamento é estabelecer um critério de término das iterações do algoritmo de aprendizagem. Como o simulador permite operar simultaneamente com dois conjuntos de padrões, um de treinamento e outro de validação, a maneira mais adequada para verificar a capacidade de generalização da rede é monitorar a queda do erro médio quadrático (EMQ) para o conjunto de validação, durante a fase de treinamento, e finalizar o processo quando esse atingir um valor mínimo (ZELL et al., 1995). Para cada um dos conjuntos de dados, o EMQ de validação obteve o valor mínimo em iterações diferentes. A síntese dos parâmetros de cada RNA utilizada e os respectivos números de ciclos e EMQs são apresentados na Tabela 4.

Tabela 4 - Configuração e resultados das inferências por RNA.

RNA	Arquitetura	Δ_0	$\Delta_{\max}$	α	Nº ciclos	EMQ _{validação}
1 – org_tds	7-5-4-1	0,1	40	4	400	0,0039068
2 – org_356	3-2-1	0,1	40	4	3400	0,0038578
3 – org_36	2-5-3-1	0,1	40	4	200	0,0037801
4 – svz_tds	7-5-4-1	0,1	40	4	200	0,0028014
5 – svz_356	3-2-1	0,1	40	4	100	0,0027334
6 – svz_36	2-5-3-1	0,1	40	4	100	0,0028917



Com relação às arquiteturas selecionadas, optou-se por manter configurações iguais para os conjuntos de dados originais e seus correspondentes suavizados, isso para que os resultados das redes fossem analisados par a par e ressaltassem a superioridade de uma combinação do conjunto de entrada em relação ao outro, minimizando a possível contribuição que diferentes arquiteturas poderiam causar no resultado.

Como já mencionado, os parâmetros do algoritmo de aprendizado foram mantidos iguais em todas as redes e os menores erros de validação foram obtidos em diferentes ciclos para cada RNA testada. De modo geral, percebe-se que o número de ciclos necessários foram relativamente pequenos, com exceção da segunda RNA (*org_356*), isso porque considera-se que o paradigma de treinamento utilizado consiste de um algoritmo de conversão mais rápida que o *backpropagation* (BRAGA et al., 2000).

A avaliação dos resultados foi feita primeiramente através dos índices fornecidos pelo *software*, que indicaram a qualidade da arquitetura escolhida, baseando-se nos dados de treinamento e validação da RNA. Percebe-se, pela Tabela 4, que os dados suavizados proporcionaram erros de validação menores que os EMQs apresentados pelos dados originais. Baseando-se nos EMQs, a melhor configuração foi aquela baseada nas bandas 3 (verde), 5 (vermelho) e 6 (vermelho limítrofe) suavizadas, embora, a seleção de bandas por feições específicas de clorofila *a* não forneceu resultados muito superiores à utilização de todas as bandas, quando utilizando tal parâmetro para análise de qualidade da rede. Assim, considera-se que a principal contribuição para melhorar os resultados da rede está associada à necessidade do tratamento da imagem multiespectral.

Após o treinamento de cada uma das redes, essas foram aplicadas à toda a extensão do reservatório Cascata. O JavaNNS fornece um resultado no formato ASCII com uma codificação própria, assim foi necessário convertê-lo a um arquivo texto simples, atribuindo também as coordenadas para cada um dos valores de clorofila gerados pela rede. Tal procedimento foi feito em uma planilha eletrônica com auxílio de equações lógicas e ferramentas de classificação de dados. Depois disso, o arquivo texto contendo as coordenadas e os valores inferidos foram importados no IDRISI Andes no formato vetorial e convertidos posteriormente para uma representação matricial, da mesma forma como foi feita a geração da imagem de clorofila coletada com o fluorômetro. As representações regradadas são apresentadas na Figura 30.






Figura 30 - Resultado da aplicação das RNAs treinadas às imagens World View-2.

Comprovando o indicado pelos erros de validação, as redes treinadas com dados suavizados apresentaram resultados de espacialização da clorofila *a* visualmente superiores às redes treinadas com dados originais. Percebe-se novamente a importância do pré-processamento das imagens e, ainda, como a característica dos dados de entrada permanece na saída da RNA, já que o efeito granuloso das imagens originais persistiu.

As representações resultantes das redes com dados originais não permitiram observar regiões com diferenças na concentração de clorofila bem definidas, enquanto que as imagens suavizadas, principalmente as representações *svz_356* e *svz_36*, possibilitaram isso. Nessas duas imagens percebe-se que a região com menores índices de clorofila ocorrem nas proximidades da nascente do manancial, na parte inferior do reservatório.

Todas as representações com imagens suavizadas apresentaram bordas bem definidas com valores pequenos de clorofila e inferiram valores de clorofila até mesmo para um local onde um duto suspenso atravessa o manancial, no pequeno braço a oeste. Nas representações com dados originais a região do duto é preservada sem valores inferidos. Assim, evidencia-se que é necessária cautela nas análises de regiões limítrofes para imagens suavizadas.

Além da análise visual, houve a tentativa de uma análise de correlação entre os valores estimados pelas redes e valores obtidos *in situ* não utilizados no treinamento, entretanto, não foi obtido resultado significativo. Isso porque a variação dos dados é muito pequena, de ordem decimal e, a utilização de uma medida associativa como a correlação, sensível a pequenas variações, não é adequada ao conjunto de dados obtidos. Ainda, efetuou-se o fatiamento das representações geradas e visando a elaboração de uma matriz de confusão, mas novamente, pelo intervalo de variação dos dados ser muito pequeno, as fatias criadas apresentaram tamanho reduzido, comprometendo igualmente as análises.

Assim, a alternativa encontrada foi realizar uma análise dos atributos estatísticos básicos dos dados, buscando compará-los com os dados coletados com o fluorômetro. A estatística descritiva de todas as espacializações geradas é apresentada na Tabela 5.



Tabela 5 - Estatística descritiva das representações geradas.

	<i>Org_tds</i>	<i>Org_356</i>	<i>Org_36</i>	<i>Svz_tds</i>	<i>Svz_356</i>	<i>Svz_36</i>	Fluorômetro
Valor mínimo	0,831	0,624	0,024	0,205	0,254	0,100	1,57
Valor máximo	2,810	3,122	2,881	3,006	2,717	2,654	5,22
Média	2,514	2,536	2,519	2,406	2,378	2,380	2,36
Desvio padrão	0,268	0,136	0,189	0,570	0,434	0,466	0,41

Pela Tabela 5 observa-se que nenhuma das redes forneceu valores mais elevados de clorofila *a*, concentrando-se na faixa onde há maior quantidade de dados (entre 2 a 3 $\mu\text{g/L}$). Novamente, as representações que mais se aproximaram dos dados de campo foram *svz_356* e *svz_36* nessa ordem, confirmando que, a partir de um conjunto de imagens multiespectrais tratadas, a seleção de bandas que contemplem regiões onde a variável de estudo interfere na resposta espectral fornece melhores resultados na inferência.

Assim, apresenta-se o resultado da combinação das bandas 3 (verde), 5 (vermelho) e 6 (vermelho limítrofe) suavizadas, que obteve o melhor desempenho em todas as análises de possível realização (Figura 31).






Figura 31 - Concentração de clorofila inferida a partir das bandas 3, 5 e 6 de uma imagem World View-2.



5. CONCLUSÕES

A realização da presente pesquisa possibilitou avaliar o uso integrado de um conjunto de dados e técnicas na inferência espacial de clorofila *a*. Percebeu-se que a interação entre dados fluorimétricos e multiespectrais forneceu bons resultados de aplicação quando combinados em uma estrutura de redes neurais artificiais, permitindo inferir a variabilidade do pigmento estudado.

O comportamento espectral das águas do reservatório Cascata mostrou tratar-se de um ambiente com baixas concentrações de componentes opticamente ativos e com características homogêneas, assim, a análise derivativa não forneceu bons resultados. Mais uma vez, ressalta-se a importância da adequação das técnicas de análise de dados espectrorradiométricos para ambientes com características peculiares nas concentrações de COAs. Ainda, destaca-se também a importância das condições de iluminação para tomada dos dados, visto que para a coleta realizada em março, tal fato comprometeu significativamente a qualidade das curvas espectrais obtidas e, nesse caso, a análise derivativa eliminou essa interferência.

Comprovou-se a eficiência de um fluorômetro de campo para estimativa de clorofila em fluxo contínuo, fornecendo uma quantidade de dados adequada à modelagem ambiental. De qualquer maneira, para obtenção de modelos confiáveis, uma etapa fundamental é a calibração dos dados fluorimétricos, assim, a análise laboratorial da água deve ser cuidadosamente executada, para viabilizar que os dados fluorimétricos representem a realidade, caso contrário deve-se explicitar que se trata de uma medida relativa. Neste trabalho, cujo corpo d'água em estudo apresentou concentrações muito pequenas da variável em questão, observa-se que as técnicas para determinação de clorofila *a* foram adequadas, uma vez que as faixas de detecção dos métodos fluorimétricos (campo) e de cromatografia líquida (laboratório) são superiores às espectrofotométricas.

Com relação à imagem multiespectral, é necessário reafirmar a importância da correção atmosférica e da análise da qualidade do modelo atmosférico aplicado. Ainda, uma análise visual combinada com o conhecimento do fenômeno estudado possibilitou identificar um comportamento não proveniente do fluxo de radiação de interesse, ou seja, da radiação volumétrica, que é a de interesse para estudos de qualidade da água. Assim, a suavização com filtro média forneceu bons resultados de aplicação.



Sobre a utilização das redes neurais artificiais, verificou-se a necessidade do conhecimento da aplicação pretendida da rede para definição das funções de ativação. Moreira (2001) e Samizawa (2007) utilizaram RNA para inferência, mas utilizaram funções logísticas para todos os elementos de processamento como funções de ativação, gerando uma saída de rede entre 0 e 1, condizente com a aplicação desses autores, visto que buscaram inferir o grau de aptidão para determinadas atividades. No caso deste trabalho, uma função logística não seria adequada, uma vez que não forneceria valores reais da concentração de clorofila *a*.

Quanto à seleção dos dados de entrada na rede, verificou-se que é necessário que os dados de entrada sejam ligados ao fenômeno que se pretende inferir. A utilização de dados não diretamente relacionados mostrou prejudicar o desempenho da rede, como foi verificado utilizando as bandas de 1 a 7.

A definição dos conjuntos de treinamento e validação deve ser feita de maneira cuidadosa, visando contemplar as principais diferenças da variável a ser inferida, caso contrário, a RNA poderá generalizar demasiadamente o resultado. No caso desse trabalho, como a variação dos valores de clorofila *a* não eram significativos, a capacidade de extrapolar valores não foi suficientemente testada.

Também foi observada a necessidade de análises complementares à análise dos erros de validação apresentados pela rede. No caso desta pesquisa, a utilização da análise visual e comparação de atributos foram as alternativas encontradas, mas para casos em que as variações do modelo são maiores, sugere-se a utilização de análises de correlação e até mesmo a construção de uma matriz de confusão que, embora nesta pesquisa o número de elementos amostrais medidos em campo fosse suficiente para a análise, a característica de homogeneidade da variável não possibilitou tais operações.

Nesse contexto, mesmo apresentando valores baixos e homogêneos de clorofila *a*, foi possível o desenvolvimento de um modelo adequado de inferência que representa as reais variações verificadas *in situ*. A presente pesquisa possibilitou a definição do conjunto de dados que mais se adequaram à realidade do ambiente de estudo para a inferência de clorofila *a*, que poderá servir de base para estudos em outros ambientes.

Por fim, recomenda-se que testes em áreas com variações expressivas de clorofila *a* sejam realizados, visando confirmar se o método empregado para áreas com pequenas variações é também eficiente em casos de alta variabilidade. Ainda, sugere-se que campanhas de campo totalmente sincronizadas com tomada da imagem sejam efetuadas, buscando



integrar os dados espectrorradiométricos na seleção das bandas para entrada na rede neural artificial.



REFERÊNCIAS BIBLIOGRÁFICAS

AMERICAN PUBLIC HEALTH ASSOCIATION . **Standard methods for the examination of water and wastewater**. 20. ed. Washington: APHA, 1998.

ARRAUT, E. M.; et al. Estudo do comportamento espectral da clorofila e dos sólidos em suspensão nas águas do lago grande de Curuai (Pará), na época da seca, através de técnicas de espectroscopia de campo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XII, 2005, Goiânia. **Anais**. São José dos Campos: INPE, p. 2447-2456.

ANALITICAL SPECTRAL DEVICES, Inc. **HandHeld Spectroradiometer: User's guide**. Boulder: ASD Inc., 2002.

ATKINSON, P. M.; TATNALL, A. R. L. Neural networks in remote sensing. *International Journal of Remote Sensing*, v. 18, n. 4, 699-709, 1997.

AZEVEDO NETO, J. M. Novos conceitos sobre eutrofização. *Revista DAE*, v. 48, n. 151, 22-28, 1988.

BAILEY, S. W.; WERDELL, P. J. A multi-sensor approach for the on-orbit validation of ocean color satellite data products. *Remote Sensing of Environment*. v. 102, n. 1-2, 12-23, 2006.

BARBOSA. C. C. F. **Sensoriamento remoto da dinâmica da circulação da água do sistema planície de Curuai/Rio Amazonas**. 2005. 255 f. Tese (Doutorado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

BARBOSA, P. C. C. **Aplicações de Fluorescência Induzida por Laser em Monitoramento Ambiental**. 2003. 139f. Tese (Doutorado em Física) – Pontifícia Universidade Católica, Rio de Janeiro.

BOCANEGRA, C. W. R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 108 p. Dissertação (Mestrado em Engenharia Civil), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. B. P. L. F. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.



BRANCO, S. M., BERNARDES, R. S. Culturas hidropônicas como forma de remoção e reciclagem de nutrientes minerais dos efluentes de sistemas de tratamento de esgotos. *Revista. DAE*, v. 134, 113-115, 1983.

BRONDINO, N. C. M. **Estudo da influência da acessibilidade no valor de lotes urbanos através do uso de redes neurais**. 1999. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

BUKATA, R. P. J. KOONDRATYEV, K.Y.; POZOZDNYAKOV, D.V. **Optical properties and remote sensing of inland and coastal waters**. Boca Raton: CRC, 1995. 362p.

BUKATA, R. P. **Satellite Monitoring of inland and coastal water quality**. Retrospection, introspection, future directions. New York: Taylor & Francis, 2005, p. 246.

BUKTON, D.; O'MONGAIN, E.; DANAHER, S. The use of Neural Networks for the estimation of oceanic constituents based on the MERIS instrument. *International Journal of Remote Sensing*, v. 20, n. 9, 1841-1851, 1999.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. São José dos Campos: INPE, 2001.

CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais**. Website. Disponível em <<http://www.icmc.usp.br/~andre/research/neural/index.htm>> Acesso em 02 de fevereiro de 2009.

CHANG, D. H.; ISLAM, S. Estimation of Soil Physical Properties Using Remote Sensing and Artificial Neural Network. *Remote Sensing of Environment*. v. 74, n. 3, 534-544, 2000.

CHEN, C.; et al. A derivative spectrum algorithm for determination of chlorophyll-a concentration in the Pearl River estuary. IN: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2007, Barcelona: IEEE Geoscience and Remote Sensing Society, 925-928. **Proceedings**.

COMPANHIA DE TECNOLOGIA DE SANEAMENTO AMBIENTAL – CETESB. **Relatório de qualidade das águas interiores do estado de São Paulo 2008**. São Paulo: CETESB, 2009.



DANSON, F. M.; ROWLAND, C. S.; BARET, F. Training a neural network with a canopy reflectance model to estimate crop leaf area index. *International Journal of Remote Sensing* v. 24, n. 23, 4891-4905, 2003.

DEKKER, A G. **Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing.** 1993. 211 f. Tese (PhD theses) Free University, Amsterdam.

DICAS de simulação de Redes Neurais. OSÓRIO, F. 2006. Disponível em <<http://osorio.wait4.org/oldsite/sadi/dicas/dicas-simulacao-snns.txt>>. Acesso em 10 abr. 2011.

DIGITAL GLOBE. World View 2. Disponível em <<http://www.digitalglobe.com/index.php/88/World View-2>>. Acesso em 20 de junho de 2010.

ENNES, R. **Potencial das imagens hiperespectrais orbitais na detecção de componentes opticamente ativos no reservatório de Itupararanga.** 2008. 126 f. Dissertação (Mestrado em Ciências Cartográficas) UNESP, Presidente Prudente.

ENVI – Environment for Visualizing Images. Website. Disponível em <<http://www.envi.com.br/>>. Acesso em 25 de junho de 2011.

ESPINHOSA, M. C. **Utilização de sensoriamento remoto orbital e redes neurais artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios.** 2004. Dissertação (Mestrado em Ciências Cartográficas) – UNESP, Presidente Prudente.

FELGUEIRAS, C. A. **Modelagem Ambiental com Tratamento de Incertezas em Sistemas de Informação Geográfica: O Paradigma Geoestatístico por Indicação.** 1999. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

FERREIRA, M. S.; GALO, M. L. B. T.; ROTTA, L. H. S.; ARAÚJO, R. R.; IMAI, N. N.; SAMIZAVA, T. M. Um estudo da distribuição espacial de pigmentos totais na planície de inundação do Alto Rio Paraná a partir de imagens multiespectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, Natal, 2009, **Anais**. São José dos Campos: INPE, p. 5211-5218.

FISCHER, I.; et al. Java Neural Network Simulator: *User Manual, Version 1.1*. Tübingen: University of Tübingen, 2001.

GALO, M. L. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do parque estadual morro do diabo.** 2000. 197p. Tese



(Doutorado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

GITELSON, A.A.; et al. Remote estimation of chlorophyll concentration in productive waters: Principals, algorithm development and validation. IN: NATIONAL MONITORING CONFERENCE, 2000, 149-160, Austin. **Proceedings of NWQMC**.

GITELSON, A.; et al. The use of high-spectral-resolution radiometer data for detection of low chlorophyll concentrations in Lake Kinneret. *Journal of Plankton Research*, v. 16, n. 8, 993-1002, 1994.

GOLTERMAN, H. L. ; CLYMO, R. S. ; OHNSTAD, M. A. M. **Methods for Physical and Chemical Analysis of Fresh Waters**. Oxford: Blackwell Scientific, 1978.

GONS, H. J.; AUER, M. T.; EFFLER, S. W. MERIS satellite chlorophyll mapping of oligotrophic and eutrophic waters in the Laurentian Great Lakes. *Remote Sensing of Environment*, v. 112, 4098-4106, 2008.

GONZALES. R. C.; WOODS. R. E. **Processamento de imagens digitais**. São Paulo: Editora Edgard Blücher Ltda., p. 509, 2000.

GOODIN, D. G. et al. Analysis of suspended solids in water using remotely sensed high resolution derivate spectra. *Photogrammetric Engineering and Remote Sensing*. Manhattan, v. 59, n. 4, 505-510, abr. 1993

GROSS, L.; et al. Artificial neural networks for modeling the transfer function between marine reflectance and phytoplankton pigment concentration. *Journal of Geophysical Resarch*. v. 105, n. C2, 3483-3495, 2000.

GUIZADO, T. R. C. **Estudos computacionais da interação de porfirinas e seus complexos de ferro com albumina sérica humana**. 2008. Dissertação (Mestrado em Física) – Pontifícia Universidade Católica, Rio de Janeiro.

HALL, D. O.; RAO, K. K. **Fotossíntese**. São Paulo: EPU, 1980.

HAYKIN, S. **Redes Neurais: Princípios e práticas**. 2 Ed. São Paulo: Bookman, 1999.

HOLLER, F. J.; SKOOG, D. A.; CROUCH, S. R. **Princípios de análise instrumental**. 6° Ed. Porto Alegre: Bookman, 2009.



ITT – VISUAL INFORMATION SOLUTIONS. **ENVI Help**. Boulder: ITT, 2010.

JANG, J. D.; VIAU, A. A.; ANCTIL, F. Neural network estimation of air temperatures from AVHRR data. *International Journal of Remote Sensing*. v. 25, n. 21, 4541-4554, 2004.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução da 2ª ed. por (pesquisadores do INPE): José Carlos N. Epiphanyo (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 672 p, 2009.

KEINER, L. E.; BROWN, C. W. Estimating oceanic chlorophyll concentrations with neural networks. *International Journal of Remote Sensing*. v. 20, n. 1, 189-194, 1999.

KEINER, L. E.; YAN, X. H. A neural network model for estimating sea surface chlorophyll and sediments from Thematic Mapper Imagery. *Remote Sensing of Environment*. v. 66, 153-165, 1998.

KIRK, J. T. O. **Light and photosynthesis in aquatic ecosystems**. 2 ed. Cambridge University Press, 1994.

LI, Y. X.; TONG, L.; PANG, B. Estimation of chlorophyll-a concentration based on the semi-analytical model and remote sensing data. IN: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2010, Honolulu: IEEE Geoscience and Remote Sensing Society, 3592-3595. **Proceedings**.

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

LONDE, L. R. **Comportamento espectral do fitoplâncton de um reservatório brasileiro eutrofizado – Ibitinga (SP)**. 2008. 223 f. Tese (Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

MARTINI, L. C. P. ; et al. Uso de sensoriamento remoto orbital para avaliação da distribuição espacial de Clorofila_a na Lagoa da Conceição – Florianópolis, SC. *Revista Engenharia Sanitária E Ambiental/Associação Brasileira De Engenharia Sanitária E Ambiental*, Rio de Janeiro, Vol. 11, nº4, p. 318 a 324, out/dez 2006.

MAS, J. F.; FLORES, J. J. The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing*. v. 29, n. 3, 617-663, 2008.



MOORE, T. S.; CAMPBELL, J. W.; DOWELL, M. D. A class-based approach to characterizing and mapping the uncertainty of the MODIS ocean chlorophyll product. *Remote Sensing of Environment*. v. 113, n. 11, 2424-2430, 2009.

MOREIRA, F. R. S. Uso e avaliação de técnicas de integração e análise espacial de dados em pesquisa mineral aplicadas ao planalto de Poços de Caldas. 2001. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

NAIR, A.; et al. Remote sensing of phytoplankton functional types. *Remote Sensing of Environment*. v. 112, n. 8, 3366-3375, 2008.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 3 Ed. São Paulo: Blucher, 2008.

PEREIRA FILHO, W. **Influência dos diferentes tipos de uso da terra em bacias hidrográficas sobre sistemas aquáticos da margem esquerda do reservatório de Tucuruí – Pará**. 2000. 136p. Tese (Doutorado em Geografia Humana) – Universidade de São Paulo, São Paulo.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007. 127 p.

QUIBELL, G. The effect of Suspended Sediment on Reflectance from Freshwater Algae. *International Journal of Remote Sensing*, v. 12, n.1, 177 – 182, jan.1991.

RICHARDS, J. A.; JIA, X. Remote Sensing digital image analysis: An Introduction. 4. ed. Australia: Springer, 2006.

ROMBOLA, T. H. Publicação eletrônica [mensagem pessoal]. Mensagem recebida de <tiago_hr@yahoo.com.br> em: 28 abr. 2011

RUDORFF, C. M. **Estudo da composição das águas da planície amazônica por meio de dados de reflectância do sensor Hyperion/EO-1 e de espectrorradiômetro de campo visando à compreensão da variação temporal dos seus constituintes opticamente ativos**. 2006. 140p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

RUDORFF, B. F. T.; SHIMABUKURO, Y. E. ; CEBALLOS, J. C. **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos: Parêntese, 2007. 423 p.



RUIZ-VERDÚ, A. et al. An evaluation of algorithms for the remote sensing of cyanobacterial biomass. *Remote Sensing of Environment*, v. 112, p. 3996-4008, 2008.

RUNDQUIST, D. C.; HAN, L.; SCHALLES, J. F.; PEAKE, J. S. Remote measurement of algal chlorophyll in surface waters: the case for the first derivative of reflectance near 690 nm. *Photogrammetric Engineering and Remote Sensing*. v. 62, n. 2, p. 195-200, fev. 1996.

SAMIZAVA, T. M. et al. Avaliação do desempenho de uma rede neural artificial na seleção de áreas potenciais para disposição de resíduos sólidos: uma comparação com um modelo baseado em conhecimento. In: SIMPÓSIO BRASILEIRO DE GEOMÁTICA E V COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, II, 2007, Presidente Prudente. **Anais**.

SANTOS, C. C. **Modelagem de bacias urbanas com redes neurais artificiais**. 2001. 105p. Dissertação (Mestrado em Engenharia) – Universidade de São Paulo, São Paulo.

SCHILLER, H.; DOERFFER, R. Neural network for emulation of an inverse model operational derivation of Case II water properties from MERIS data. *International Journal of Remote Sensing*. v. 20, n. 9, 1735-1746, 1999.

SIERRA, M. M. S.; GIOVANELA, M.; DONARD, O. F. X.; BELIN, C. A utilização de espectroscopia de fluorescência no estudo da matéria orgânica dissolvida nas águas naturais: Evolução e perspectivas. **Química Nova**, São Paulo, v. 19, n. 3, p. 294-301, 1996.
STREIT, N. M.; CANTERLEL, L. P.; CANTO, M. W.; HECKTHEUER, L. H. H. As clorofilas. *Ciência Rural*. v 35, n 3, p 748-755, 2005.

TRONTO, I. F. B. **Uma metodologia baseada em modelos estatísticos e redes neurais para a estimativa de esforço de desenvolvimento de software**. 2007. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

TSAI F., PHILPOT W. Derivative Analyses of Hyperspectral Data. **Remote sensing Environment**, St. Paul, v. 66, p. 41–51, 1998.

TUNDISI, J. G. **Água no século XXI: enfrentando a escassez**. São Carlos: RIMA, IIe, 2003. 248p.

TUNDISI, J. G.; TUNDISI, T. M. **Limnologia**. São Paulo: Oficina de Textos, 2008.



TURNER DESIGNS. **An *in vivo* chlorophyll procedure for the 10AU field fluorometer.** 1999. Disponível em: <http://www.turnerdesigns.com/t2/doc/appnotes/alg.html>. Acesso em: 10 de junho de 2010.

TURNER DESIGNS. **Cyanobacteria detection in water using *in vivo* fluorometry.** 2004. Disponível em: <http://www.turnerdesigns.com/t2/doc/appnotes/alg.html>. Acesso em: 10 de junho de 2010.

TURNER DESIGNS. **Frequently asked questions about chlorophyll.** 1998. Disponível em: <http://www.turnerdesigns.com/t2/doc/appnotes/alg.html>. Acesso em: 10 de junho de 2010.

UPDIKE, T.; COMP, C. Radiometric use of World View-2 imagery. Technical Note. Digital Globe, 2010.

VELOSO, T. S. Fluxos de calor na superfície e evapotranspiração diária em áreas agrícolas e de vegetação nativa na bacia do Jacuí por meio de imagens orbitais. 2009. Dissertação (Mestrado em Sensoriamento Remoto). Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre.

WERDELL, P. J.; et al. Regional and seasonal variability of chlorophyll-a in Chesapeake Bay as observed by SeaWiFS and MODIS-Aqua. Remote sensing of phytoplankton functional types. *Remote Sensing of Environment*. v 113, n 6, 1319-1330, 2009.

YACOBI, Y. Z.; GITELSON, A.; MAYO, M. Remote sensing of chlorophyll in Lake Kinneret using high-spectral-resolution radiometer and Landsat TM: spectral features of reflectance and algorithm development. *Journal of Plankton Research*, v. 17, n.11, 2155-2173, 1995.

ZELL, A. et al. SNNS: Stuttgart Neural Network Simulator: *User Manual, Version 4.1*. Stuttgart: University of Stuttgart, 1995.

WETZEL, R. G. **Limnology: Lake and river ecosystems.** 3 Ed. San Diego: Academic Press. 2001.

ZULLO JR., J. **Correção atmosférica de imagens de satélite e aplicações.** 1994. 204p. Tese (Doutorado em Engenharia Elétrica). Universidade Estadual de Campinas, Campinas.



APÊNDICES

APÊNDICE A - SINCRONIZAÇÃO ENTRE AS COORDENADAS OBTIDAS COM RECEPTOR GPS E DADOS COLETADOS PELO FLUORÔMETRO DE CAMPO


Sincronização feita pelo horário de coleta dos dados. Exemplo:

COORDENADAS COLETADAS PELO RECEPTOR GPS				DADOS FLUOROMÉTRICOS CALIBRADOS		
Data (dd/mm/aaaa)	Hora GMT	N	E	Data (mm/dd/aa)	Hora local	[Chl-a] ($\mu\text{g/L}$)
18/3/2011	12:27:00	7543127,256	610895,209	03/18/11	09:27:02	2,59074
18/3/2011	12:27:05	7543127,219	610895,115	03/18/11	09:27:07	2,615247
18/3/2011	12:27:10	7543127,156	610895	03/18/11	09:27:12	2,828808
18/3/2011	12:27:15	7543127,287	610894,866	03/18/11	09:27:17	2,828808
18/3/2011	12:27:20	7543128,006	610894,022	03/18/11	09:27:22	2,821806
18/3/2011	12:27:25	7543128,447	610893,127	03/18/11	09:27:27	3,073878
18/3/2011	12:27:30	7543128,949	610892,199	03/18/11	09:27:32	3,042369
18/3/2011	12:27:35	7543129,344	610890,958	03/18/11	09:27:37	2,856816
18/3/2011	12:27:40	7543129,359	610890,75	03/18/11	09:27:42	2,541726
18/3/2011	12:27:45	7543127,988	610891,373	03/18/11	09:27:47	2,457702
18/3/2011	12:27:50	7543125,959	610891,252	03/18/11	09:27:52	2,639754
18/3/2011	12:27:55	7543123,802	610891,195	03/18/11	09:27:57	3,126393
18/3/2011	12:28:00	7543122,357	610892,79	03/18/11	09:28:02	2,734281
18/3/2011	12:28:05	7543121,56	610894,14	03/18/11	09:28:07	2,912832
18/3/2011	12:28:10	7543121,143	610894,77	03/18/11	09:28:12	3,280437
18/3/2011	12:28:15	7543121,021	610895,153	03/18/11	09:28:17	3,11589
18/3/2011	12:28:20	7543120,51	610898,167	03/18/11	09:28:22	3,056373
18/3/2011	12:28:25	7543119,147	610901,423	03/18/11	09:28:27	3,122892
18/3/2011	12:28:30	7543117,05	610904,943	03/18/11	09:28:32	2,440197
18/3/2011	12:28:35	7543114,615	610908,709	03/18/11	09:28:37	2,086596
18/3/2011	12:28:40	7543112,362	610912,867	03/18/11	09:28:42	2,181123



APÊNDICE B - GERAÇÃO DOS ARQUIVOS DE PADRÕES PARA ENTRADA NO JAVANNS

1. As imagens contendo áreas de treinamento, validação e toda a extensão do ambiente de estudo, definidas no aplicativo ENVI 4.8, foram salvas em formato ASCII. O procedimento foi efetuado para cada uma das bandas, gerando arquivos como o apresentado abaixo.




```

1 ;
2 ; ENVI ASCII Output of file: D:\Meus documentos\PPGCC-UNESP\Campo Marília_2011\Dados processados\Prontos p
3 ; File Dimensions: 286 samples x 310 lines x 1 band
4 ; Line Format      : (f14.2,f14.2,f14.4)
5 ;
6      610564.00      7543160.00      0.0000
7      610566.00      7543160.00      0.0000
8      610568.00      7543160.00      0.0000
9      610570.00      7543160.00      0.0000
10     610572.00      7543160.00      0.0000
11     610574.00      7543160.00      0.0000
12     610576.00      7543160.00      0.0000
13     610578.00      7543160.00      0.0000
14     610580.00      7543160.00      0.0000

```

2. Os arquivos anteriores tiveram sua extensão alterada de *.txt para *.nns e processados em programa³ usado para produzir os arquivos dos padrões de treinamento, validação e teste para o simulador.

3. Os arquivos *.nns foram reunidos em um mesmo diretório e foi feita a edição do arquivo *snns_entradaPAR*, a partir da seleção dos parâmetros para a geração do arquivo de padrões pelo aplicativo *snns_entrada_NNS*.



```

1 27inteira_3raz65.pat
2
3 n
4 1
5 2
6 1
7 I3.nns i_r65.nns IPRETA.nns
8
9
10 #####
11 Information about the parameters to be included in snnsPAR file
12
13 For more details:
14
15 SNNS - Stuttgart Neural Network Simulator
16 User Manual, Version 4.1 - Report No. 6/95
17 University of Stuttgart
18 #####
19 Line 1) Output file name (with extension .pat) ?
20 Line 2) No. of variable input dimensions <1,2> (1 to 1D, 2 to 2D) ?
21 Line 3) Apply maximum contrast stretch during data conversion ? <y,n>
22 Line 4) No. of patterns ?
23 Line 5) No. of input units ?
24 Line 6) No. of output units ?
25 Line 6) Pattern 1 : Input unit 1, 2, ... , Output unit
26 Line 7) Pattern 2 : Input unit 1, 2, ... , Output unit
27
28 Line n) Last Pattern : Input unit 1, 2, ... , Output unit
29

```

³ Programa desenvolvido pelo Prof. Dr. Maurício Galo (galo@fct.unesp.br)



4. Após a edição do arquivo *snns_entradaPAR*, o aplicativo foi executado, gerando o arquivo de padrões (*.pat) baseando-se nos parâmetros especificados.

```

C:\Documents and Settings\HomeUser\Meus documentos\teste\snns_entrada_NNS.exe

Generation of 'PAT' files to be used in 'SNNS'

To get more details see:

          SNNS - Stuttgart Neural Network Simulator
          User Manual, Version 4.1 - Report No. 6/95
          University of Stuttgart

Arquivos .nns disponíveis nesta área:

O volume na unidade C não tem nome.
O número de série do volume é 2898-D8FB

Pasta de C:\Documents and Settings\HomeUser\Meus documentos\teste
27/06/2011 06:10          3.901.051 I3.nns
10/06/2011 13:22          3.901.052 IPRETA.nns
27/06/2011 06:38          2.039.197 i_r65.nns
          3 arquivo(s)          9.841.300 bytes
          0 pasta(s)          4.579.667.968 bytes disponíveis

...
Information read in snns_entradaPAR file.

Output file name -----> 27inteira_3raz65.pat
No. of patterns -----> 1
No. of input/output unit -----> 2/1
No. of input/output dimension -----> 2/2
Apply maximum constraint -----> n

Begin of PATTERN 1

Input file 1 ----[ 286H x 310U]-----> I3.nns
Input file 2 ----[ 286H x 310U]-----> i_r65.nns
Output file 1 ----[ 286H x 310U]-----> IPRETA.nns

Output file : 27inteira_3raz65.pat
End of 'SNNS_ENTRADA_NNS.EXE' processing.
Press Enter to close this Window.

```

```

Arquivo  Editar  Localizar  Visualizar  Formatar  Linguagem  Configurações  Macro  Executar  Plugins  Janela  ?

snns_entradaPAR  27inteira_3raz65.pat

1  SNNS pattern definition file V3.2
2  generated at
3
4  No. of patterns : 1
5  No. of input units : 2
6  No. of output units : 1
7  No. of variable input dimensions : 2
8  Maximum input dimensions : [ 286 310 ]
9  No. of variable output dimensions : 2
10 Maximum output dimensions : [ 286 310 ]
11
12 # Input units joint 1: I3.nns + i_r65.nns
13 [ 286 310 ]
14 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
15 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
16 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
17 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
18 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
19 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
20 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
21 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
22 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
23 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
24 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
25 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
26 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
27 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000
28 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000 0.00000


Normal text file          length : 2129462  lines : 637          Ln : 1  Col : 1  Sel : 0          Dos/Windows  ANSI  INV

```



APÊNDICE C - CONVERSÃO DO RESULTADO DA INFERÊNCIA FEITA NO JAVANNS PARA ARQUIVOS ASCII

1. O JavaNNS fornece como resultado da aplicação de uma RNA treinada, um arquivo *.res, que pode ser visualizado abaixo.



The screenshot shows a text editor window titled 'orgRES_NET_36_2531'. The menu bar includes 'Arquivo', 'Editar', 'Localizar', 'Visualizar', 'Formatar', 'Linguagem', 'Configurações', 'Macro', 'Executar', 'Plugins', and 'Janela'. The toolbar contains various icons for file operations. The text area displays the following content:


```
1 SNNS result file V1.4-3D
2 generated at Fri Jun 24 21:54:06 2011
3
4 No. of patterns      : 88660
5 No. of input units  : 2
6 No. of output units : 1
7 startpattern        : 1
8 endpattern          : 1
9 #1.1
10 0.00138
11 #1.2
12 0.00138
13 #1.3
14 0.00138
15 #1.4
16 0.00138
17 #1.5
18 0.00138
19 #1.6
20 0.00138
21 #1.7
22 0.00138
23 #1.8
24 0.00138
25 #1.9
26 0.00138
27 #1.10
28 0.00138
29 #1.11
```

The status bar at the bottom indicates 'Normal text file', 'length : 1759771', 'lines : 177329', 'Ln : 1', 'Col : 1', 'Sel : 0', 'Dos/Windows', 'ANSI', and 'INS'.


2. O arquivo *.res fornece apenas uma série de valores, assim foi necessária sua conversão e atribuição de coordenadas para posterior geração da imagem resultante da inferência. Para isso, primeiramente converteu-se o arquivo para o formato texto (*.txt) e o mesmo foi importado para uma planilha eletrônica.

3. Na planilha eletrônica, foi utilizada uma função lógica, com o intuito de obter apenas os valores inferidos pela rede (coluna B), excluindo-se o cabeçalho referente a cada valor (#1._) do arquivo original.






4. A coluna resultante dessa operação foi reproduzida em outro espaço, utilizando a operação “Colar como valores e formatos de número” (coluna E) e à sua direita (coluna D) foi inserida uma coluna com valores de 1 a n (tamanho do arquivo *.res), isso para que seja possível eliminar as células nulas.



5. Classificou-se a coluna E através dos menores valores para os maiores, expandindo a classificação para colunas adjacentes.

6. Com isso, foram eliminados os valores da coluna D que não possuíam correspondência na coluna E.






	A	B	C	D	E	F
88656	0,00103	0,00103		58938	3,00224	
88657	#1.44329			31956	3,01297	
88658	0,00103	0,00103		67274	3,02088	
88659	#1.44330			57232	3,03889	
88660	0,00103	0,00103		14594	3,08506	
88661	#1.44331			35674	3,12203	
88662	0,00103	0,00103				
88663	#1.44332					
88664	0,00103	0,00103				
88665	#1.44333					
88666	0,00103	0,00103				
88667	#1.44334					
88668	0,00103	0,00103				
88669	#1.44335					
88670	0,00103	0,00103				

7. Utilizou-se uma classificação da coluna D, dos menores para os maiores valores e uma expansão da seleção para colunas adjacentes, o que permitiu que os valores inferidos pelo simulador JavaNNS retornassem à sua ordenação inicial, apenas sem o cabeçalho de identificação.

8. Finalmente, a coluna E, com os valores inferidos pelo JavaNNS, foi reproduzida ao lado das coordenadas das imagens submetida à inferência, tais coordenadas foram extraídas do arquivo ASCII que possibilitou a geração dos arquivos de padrões.



	A	B	C	D	E	F	G	H	I
1	#1.1			1			610564	7543160	0,00103
2	0,00103	0,00103		2	0,00103		610566	7543160	0,00103
3	#1.2			4	0,00103		610568	7543160	0,00103
4	0,00103	0,00103		6	0,00103		610570	7543160	0,00103
5	#1.3			8	0,00103		610572	7543160	0,00103
6	0,00103	0,00103		10	0,00103		610574	7543160	0,00103
7	#1.4			12	0,00103		610576	7543160	0,00103
8	0,00103	0,00103		14	0,00103		610578	7543160	0,00103
9	#1.5			16	0,00103		610580	7543160	0,00103
10	0,00103	0,00103		18	0,00103		610582	7543160	0,00103
11	#1.6			20	0,00103		610584	7543160	0,00103
12	0,00103	0,00103		22	0,00103		610586	7543160	0,00103
13	#1.7			24	0,00103		610588	7543160	0,00103
14	0,00103	0,00103		26	0,00103				

9. As colunas G, H e I foram transferidas para um editor de texto e salvas em formato *.txt, cuja manipulação em aplicativos de SIG e processamento de imagens digitais possibilitaram sua conversão em imagem *.tiff.

