

Utilização da Geoestatística e Redes Neurais Artificiais na inferência espacial de fitoplâncton em estágios iniciais de floração

Maria de Lourdes Bueno Trindade Galo
Monique Sacardo Ferreira
Alex Garcez Utsumi

Universidade Estadual Paulista “Julio de Mesquita Filho” - Unesp/FCT
Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente
Caixa Postal 96 - 13416-000 – Presidente Prudente - SP, Brasil

mlourdes@fct.unesp.br, mosacardo@hotmail.com, alex_utsumi@yahoo.com.br

Abstract. Blooms of phytoplankton are associated with increased levels of nutrients in aquatic environments from external sources of pollution. Lakes ponds and reservoirs, including those used for human consumption, are susceptible to the development of algae species potentially toxic, increasing the risk for population and aquatic ecosystem. The activity of phytoplankton in the water can be monitored by quantifying the levels of chlorophyll-a, a photosynthetic active pigment present in all phytoplankton, which shows specific features of absorption and scattering of electromagnetic radiation. In this context, the purpose of this study is performing the spatial inference of chlorophyll-a concentration, by using different interpolation methods that allow representing its variability in early-stage phytoplankton bloom. The study was conducted in two different experimental areas and the measurements of chlorophyll-a concentration was performed using in vivo fluorometry, based on the fluorescent properties of the pigment. For the spatial inference of chlorophyll-a were considered two approaches: Geostatistics, using Ordinary Kriging to perform the spatial inference in non-sampled locations, and Artificial Neural Network (ANN), extracting input data of a WorldView-2 multispectral image. For both experimental areas were obtained small values of chlorophyll-a fluorescence and, consequently, low concentrations of pigment, indicating little photosynthetic activity. Both ordinary kriging as the trained ANN generated values representing the concentrations measured in situ, showing its effectiveness in capturing the characteristics of the phenomenon and also its small spatial variability.

Palavras-chave: fluorimetry, spatial inference, artificial neural network, geostatistics, fluorimetria, inferência espacial, redes neurais artificiais, geoestatística.

1. Introdução

O impacto das ações humanas sobre os recursos hídricos, principalmente aqueles resultantes de atividades agrícolas, urbanas, industriais, geração de energia elétrica, lazer aquático, etc., se manifesta na forma de sistemas ecológicos instáveis, favorecendo o desenvolvimento acelerado e, por vezes fora de controle, de organismos como o fitoplâncton. A floração (*bloom*) de algas pode prejudicar a própria sobrevivência desses ecossistemas e inviabilizar o aproveitamento adequado dos recursos hídricos, com danos inclusive à saúde pública. Dentre outros efeitos negativos causados por tais atividades destaca-se a eutrofização dos ecossistemas aquáticos.

A introdução maciça de nutrientes na água propicia o desenvolvimento de florações (*blooms*) de algas em lagos, açudes e represas. As florações ocorrem quando as densidades populacionais, geralmente limitadas a poucas espécies, estão extremamente elevadas. Algumas algas, em especial as do grupo cianofíceas ou cianobactérias, cujo principal pigmento é a ficocianina, produzem toxinas altamente perigosas (hepatoxinas e neurotoxinas), que são prejudiciais à saúde pública e catastróficas para o ecossistema aquático (Vicent et al, 2004).

Desse modo, a caracterização da qualidade da água deve incluir o monitoramento da floração de algas nos ambientes aquáticos, considerando dois aspectos: onde se concentra e em que grau ocorre a atividade fitoplanctônica. A legislação vigente fornece parâmetros para classificar a água como sendo adequada para determinados usos e disponibiliza concentrações de referência, inclusive para a clorofila. Entretanto, Velini et al. (2002) apresentam críticas a

essa forma de classificar a qualidade da água devido às limitações inerentes a uma categorização baseada na hipótese de homogeneidade espacial da água em toda superfície desses reservatórios. Amostras, com dados georreferenciados, da Represa de Porto Primavera demonstraram que ocorrem variações da qualidade da água no espaço e no tempo.

O fitoplâncton é um grupo heterogêneo formado principalmente por algas fotossintetizantes que se distribui por grande parte dos ambientes marinhos e aquáticos continentais do mundo. Sua função nesses ambientes é captar a energia eletromagnética e transformá-la em energia química, por meio da fotossíntese (Arraut et al., 2005). A clorofila-a é o principal pigmento que absorve radiação eletromagnética para a realização da fotossíntese, estando presente em todo o fitoplâncton. Por esse motivo, sua detecção é um parâmetro de grande importância para avaliar a qualidade da água.

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 “in situ” ou a partir de bandas espectrais de imagens de sensoriamento remoto.

Além disso, a clorofila é 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 (Holler et al., 2009).

A utilização do Sensoriamento Remoto na detecção de características potencialmente nocivas à qualidade das águas tem se mostrado uma alternativa viável, no caso das substâncias da água que apresentam propriedades ópticas. Além disso, a inferência espacial das concentrações de tais pigmentos no corpo d’água passa a ser um importante indicador da qualidade da água, à medida que permite localizar os locais mais críticos dessa ocorrência.

Nesse contexto, a geoestatística se apresenta como uma importante ferramenta para descrever fenômenos naturais. Com a geoestatística, primeiramente pode-se verificar a existência de autocorrelação espacial do fenômeno de interesse e depois estimar valores em locais onde as observações não foram coletadas, estendendo o mapeamento para toda a área de estudo.

Outra possibilidade que se apresenta para a modelagem da distribuição espacial de variáveis fotossinteticamente ativas é a utilização de Redes Neurais Artificiais (RNAs). Na maior parte das aplicações de RNA, a inferência da variável utiliza dados de sensoriamento remoto como entrada, os quais são usados no treinamento da mesma, ajustando um modelo que 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 em várias áreas do conhecimento.

Considerando o exposto, o objetivo deste trabalho é realizar a inferência espacial da clorofila-a, por meio de diferentes métodos de interpolação que viabilizem representar a variabilidade na concentração desse pigmento fotossinteticamente ativo, em condições de pré-florescimento do fitoplâncton. Isto remete à necessidade de utilização de um instrumento sensor que permita detectar baixas concentrações do pigmento e de um método que permita inferir suas concentrações em locais não amostrados.

2. Características espectrais e fluorimétricas do fitoplâncton

As células e colônias presentes no fitoplâncton espalham e absorvem a luz, podendo ter uma significativa contribuição no comportamento do espalhamento total do meio aquático, mas em uma proporção que varia de acordo com cada espécie (Kirk, 1994).

A clorofila-a é geralmente considerada a componente quantificável do fitoplâncton, uma vez que ela está presente em todos os grupos algais. Ela tem como função ser o centro de reação fotossintética e possui dois picos de absorção: um no azul (em 433 nm, chamado "Soret") e outro no vermelho (em 686 nm, chamado pico "alpha").

A clorofila-a, ao ser introduzida na água pura, provoca alterações nas suas características de reflectância espectral. Quatro feições de espalhamento e absorção por clorofila são evidentes em águas onde este pigmento é abundante (Jensen, 2009): forte absorção da luz pela clorofila-a entre 400 e 500 nm; também forte absorção da luz vermelha em aproximadamente 675 nm; reflectância máxima em torno de 550 nm (pico do verde); e um pico de reflectância em torno de 690-700 nm, causado pelo espalhamento celular de algas e de um efeito combinado mínimo de absorção por pigmento de água.

Quando uma molécula absorve a radiação eletromagnética, a forma como ela retorna ao estado fundamental é regida pela sua estrutura e pelas propriedades físico-químicas do seu ambiente local. No retorno ao estado fundamental podem acontecer três processos: perda de calor; transferência de energia a uma molécula adjacente; ou emissão de um fóton. Se essa emissão é de um estado singlete, o processo é chamado de fluorescência, e o grupo molecular que emite a radiação é chamado de fluoróforo (Nakaema; Sanches, 1999).

A energia de excitação, no sistema fotossintético ou em uma molécula, pode ser perdida pela re-emissão da radiação. Em células algais fotossintetizadoras, apenas uma pequena proporção (1%) da luz absorvida é perdida desta forma. A maioria da energia absorvida se for capturada inicialmente pela clorofila, carotenóide ou ficobiliproteína, é transferida por ressonância indutiva para os centros de reação para acarretar mudanças bioquímicas (Kirk, 1994).

Apesar dessa baixa proporção em relação ao total de luz absorvida, o monitoramento por fluorescência dos pigmentos de organismos fotossintetizantes tem se mostrado uma técnica particularmente interessante, pois, a fluorescência é percebida externamente ao organismo de forma não destrutiva, permitindo uma melhor estimativa da concentração dos pigmentos. O poder de detecção da fluorescência é três vezes superior que ao de espectrometria de absorção, permitindo ser utilizada quando as concentrações são baixas ou a sua amplitude de variação é reduzida. Além disso, o método realizado em campo possibilita coletar um grande número de elementos amostrais, bem como a obtenção de dados em fluxo contínuo (Turner Designs, 2004).

A clorofila-a, naturalmente, absorve a luz azul e emite a luz vermelha. Assim, ela pode ser detectada pela fluorescência pela transmissão de um feixe de excitação de luz em 440 nm (azul) e pela detecção de luz emitida pela amostra em 680 nm (vermelho). Geralmente, a emissão de luz é diretamente proporcional a concentração do material em questão (Turner Designs, 2004).

3. Inferência Espacial

A inferência de dados com base em variáveis correlacionadas no espaço e tempo vem sendo realizada em trabalhos cujo interesse é modelar analiticamente o meio ambiente. Modelos ambientais são representações matemáticas criadas para mostrar fenômenos ou processos do mundo real. 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 (Felgueiras, 1999).

Representar computacionalmente fenômenos contínuos que ocorrem dentro de regiões geográficas é útil para conhecê-los e, assim, fornecer suporte para tomadas de decisão com menor grau de incerteza. Entretanto, na maioria dos casos, só é possível obter medidas discretas de variáveis que nos fornecem indicações relacionadas ao fenômeno de interesse.

Portanto, é necessário adotar um procedimento de interpolação a fim de produzir uma representação adequada para manipulações no computador.

Diversos métodos podem ser usados para realizar a inferência de valores em locais não observados com base em valores amostrados. Dentre eles, a geoestatística destaca-se pela possibilidade de realizar estimativas baseadas na correlação entre os valores de um fenômeno em diferentes posições, procurando representar o grau de dependência espacial entre os valores distribuídos no espaço para realizar a reconstrução de uma superfície.

A geoestatística é utilizada quando as variáveis da área geográfica em estudo são caracterizadas por apresentar variação de um local para outro com algum grau de continuidade. Uma variável nessa situação tem a tendência de apresentar valores próximos em pontos vizinhos e valores cada vez mais diferentes conforme os pontos ficam mais distantes (Landim, 1998). Em geoestatística essa variável é denominada variável regionalizada.

As ferramentas fundamentais da geoestatística no estudo do comportamento das variáveis regionalizadas são o semivariograma e a interpolação por krigagem (Landim, 1998). O semivariograma mostra o grau de dependência espacial entre os elementos da amostra de uma variável. Para o estudo dessas variáveis regionalizadas é importante conhecer os principais parâmetros do semivariograma: patamar, efeito pepita, contribuição e alcance (Camargo, 1997).

Outra alternativa para a realização da inferência espacial é a utilização de Redes Neurais Artificiais (RNA) que, matematicamente, podem ser entendidas como modelos de inferência multidimensionais e não-lineares. O grande apelo desses modelos está na sua capacidade de “aprender”, generalizar ou extrair regras automaticamente de conjuntos de dados complexos.

Os modelos de RNA representam um tipo especial de processamento da informação: são sistemas conexionistas constituídos de células primitivas que trabalham em paralelo e são conectadas por ligações diretas. A principal função dessas células é distribuir padrões de ativação através de suas conexões, de maneira similar ao mecanismo básico do cérebro humano, onde o processamento da informação se baseia na transferência de ativação de um grupo de neurônios para outro, através das sinapses (Zell et al., 1995).

De acordo com Lippmann (1987), os elementos de processamento são conectados através de pesos e cada nó produz um somatório das várias entradas, ponderadas pelos pesos de suas respectivas conexões, passando o resultado para uma função de decisão, cujo limiar interno e tipo da função é que caracterizam os nós. Os modelos de redes neurais são especificados pela topologia da rede (sua arquitetura), as características dos nós (tipo e limiar interno da função de decisão usada) e pelas regras de treinamento ou aprendizagem utilizadas. Através destas regras é estabelecido um conjunto inicial de pesos e definido como os pesos devem ser adaptados durante o uso (treinamento da rede).

O algoritmo de treinamento mais conhecido para aprendizagem supervisionada de uma rede multicamadas é o chamado *backpropagation*. Para Lippmann (1987), esse algoritmo permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do quadrado do erro (ou o erro médio quadrático) entre a saída calculada por uma arquitetura multicamadas e a saída desejada. O componente essencial desse algoritmo é o método iterativo que propaga regressivamente o erro requerido para adaptar os pesos, a partir dos neurônios da camada de saída para os nós das camadas precedentes. Após a aprendizagem da rede, ela utilizará o conjunto de pesos ajustados durante a fase de treinamento para inferir as características de um dado padrão apresentado.

4. Experimentos

Os métodos de inferência geoestatística e por RNA foram aplicados a duas áreas testes diferentes, de acordo com as características da área e disponibilidade de dados adequados a cada um. A inferência geoestatística foi realizada em um pequeno trecho de 17 ha inserido no

reservatório de Nova Avanhandava, localizado no médio curso do Rio Tietê. Essa área foi selecionada a partir de levantamentos exploratórios preliminares, nos quais se constatou atividade fitoplanctônica.

A inferência por RNA implica foi realizada na Represa Cascata, localizada 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). Para este corpo d'água foi adquirida uma imagem de alta resolução espacial WorldView-2 e, portanto foram extraídas medidas de Fator de Reflectância de Superfície em oito intervalos espectrais (conforme procedimento descrito em Ferreira, 2011), definidos pelas bandas espectrais desse sistema sensor, cujas características são apontadas na Tabela 1.

Tabela 1. Características gerais do sistema orbital WorldView-2

Órbita	Heliossíncrona
Altitude	770 km
Resolução espacial	0,46 m no modo pancromático / 1,84 m no modo
Bandas espectrais	8 (1-Costal, 2-Azul, 3-Verde, 4-Amarelo, 5-Vermelho, 6-Vermelho Limítrofe, 7- IVP1 e 8-IVP2)
Resolução	11 bits

(Adaptado de Digital Globe, 2010).

Para ambos experimentos, os dados de referência sobre a concentração de clorofila-a foram medidos “in situ”, por meio de fluorimetria de campo. O fluorômetro 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. O instrumento 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. Assim, é usual realizar a coleta de água em alguns pontos amostrais georreferenciados, simultaneamente à fluorimetria, para a determinação laboratorial da concentração de clorofila-a.

4.2 Inferência Geoestatística

Na interpolação por krigagem, adota-se como regra prática um valor mínimo de 60 elementos amostrais, mas bons resultados foram relatados para 40 pontos amostrais. Assim, as medidas foram distribuídas em toda a área de estudo, realizando-se uma aquisição com maior frequência amostral em locais onde se esperava variabilidade e maiores valores de concentração dos pigmentos fitoplanctônicos.

Desse modo, foram selecionados 70 pontos para aquisição dos valores de fluorescência *in vivo* da clorofila-a. Foram coletadas, também, amostras de água em 9 pontos georreferenciados distintos, as quais foram acondicionadas para posterior análise laboratorial e construção da curva de calibração entre os dados de fluorescência *in vivo* da clorofila-a com os dados de concentração de clorofila-a obtidos pelo de extração em laboratório.

Dos 70 pontos amostrais inicialmente coletados em campo por fluorimetria, foram excluídos 11 elementos amostrais identificados como degradados, utilizando-se 40 elementos da amostra para modelagem, já que 19 (aproximadamente 30% da amostra) foram separados para a validação.

A partir dos dados fluorimétricos calibrados para concentração de clorofila-a iniciou-se o processo de inferência, usando o método da Krigagem Ordinária. Para esse método de inferência é necessário avaliar o grau de dependência espacial entre os elementos da amostra.

Isso foi feito com a geração do semivariograma omnidirecional e também semivariogramas para as direções de 0°, 45°, 90° e 135°, com abertura angular de 45°. A partir dessa análise foram definidas a direção de maior e menor alcance, foi feita a modelagem dos semivariogramas, com base na isotropia ou anisotropia do fenômeno e aplicado o método para interpolação dos dados de concentração de clorofila-a, conforme descrito por Utsumi, 2012.

4.3 Inferência espacial por Redes Neurais Artificiais

A inferência espacial da clorofila-a realizada a partir de uma RNAI, se baseou em medidas georreferenciadas da variável feitas pelo fluorômetro de campo nos dias 17 e 18 de março de 2011 e na imagem multiespectral WorldView-2 tomada em 20 de março de 2011, a qual foi corrigida radiometricamente.

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, separando-se o conjunto de 728 observações em 282 elementos amostrais de clorofila-a para treinamento, 260 elementos para validação e 186 elementos pontuais para analisar a qualidade da representação gerada. Os arquivos de treinamento e validação foram submetidos a um simulador de Redes Neurais da Universidade de Stuttgart, especificamente usando uma versão desenvolvida em Java – JavaNNS (Fisher et al., 2001), disponível em <http://www.ra.cs.uni-tuebingen.de/SNNS/>.

Assim, foram usados como dados de entrada as bandas espectrais do sensor WorldView-2, nas quais a presença de clorofila pode alterar a resposta espectral da água, com valor de Número Digital convertido em reflectância de superfície das bandas originais e suavizadas com um filtro pela média. Cada um dos conjuntos de bandas foi combinado de formas distintas, avaliados em vários testes, nos quais foram alterados os parâmetros de treinamento, a fim de identificar a arquitetura treinada que resultasse em menor erro de validação, conforme apresentado em Ferreira (2011).

5. Inferências e análise dos resultados


Após efetuar a modelagem, fez-se a interpolação dos dados de clorofila-a por meio da Krigagem Ordinária, usando o variograma omnidirecional esférico e os 40 pontos separados previamente. O raio de interpolação com valor de 70 metros foi o mais indicado e por esse motivo utilizou-se esse valor. O resultado da interpolação por Krigagem Ordinária da clorofila-a, bem como a distribuição espacial da variância do erro de estimação para essa variável são apresentados na Figura 1.

Os valores de concentração de clorofila-a obtidos foram abaixo de 10 ppb para toda a área de estudos, indicando a eficiência da fluorescência *in vivo* na detecção do pigmento (Figura 1(a)). Já pela Figura 1(b) verifica-se que a variância do erro de estimação da concentração do pigmento é maior na região superior da área de estudos, definindo essas regiões como aquelas em que se tem menor confiabilidade na estimativa realizada.

A arquitetura de RNA com 3 elementos de entrada e 2 escondidos (3-2-1) resultou em menor erro de validação, mas apenas quando se usou as bandas espectrais da imagem WorldView-2, referentes ao 3 (verde), 5 (vermelho) e 6 (vermelho limítrofe) suavizadas (erro igual a 0,0027334). Na verdade, considerou-se que a principal contribuição no melhor desempenho da rede está associada ao tratamento da imagem multiespectral (nesse caso,


filtragem pela média) e não ao tamanho da arquitetura da rede, pois a mesma arquitetura aplicada às mesmas bandas originais, resultou em erro de validação igual a 0,0038578.

Figura 1. Distribuição espacial da concentração de clorofila-a na área de estudos em ppb (a); mapa da variância do erro de estimação da variável (b).



Na Figura 2, são mostrados os resultados da inferência espacial gerada pela RNA, a partir da reflectância espectral obtidas dessas bandas espectrais originais (a) e suavizadas (b) e arquitetura 3-2-1.

Figura 2. Representação espacial da concentração de clorofila-a (em ppb) inferida pela RNA com bandas 3, 5 e 6 originais (a) e suavizadas pela média (b).



Nas imagens mostradas na Figura 2 percebe-se claramente não apenas as baixas concentrações de clorofila-a na área de estudos, mas também a homogeneidade do corpo d'água para essa variável. Nota-se também que os locais onde a concentração do pigmento é sutilmente maior são percebidos apenas na inferência resultante da utilização das bandas espectrais suavizadas. Para avaliar a adequação dos valores inferidos fez-se uma análise dos atributos estatísticos básicos dos dados e, ao compará-los com os dados coletados com o fluorômetro, obteve-se uma concentração média de 2,378 ppb e desvio padrão igual a 0,434, para a inferência realizada pela RNA com bandas suavizadas, contra uma média de 2,36 ppb e desvio padrão de 0,41, calculados a partir do conjunto de medidas feitas pelo fluorômetro.

6. Conclusões

A partir dos resultados da inferência espacial da clorofila-a constatou-se que os valores das concentrações foram baixas para as duas áreas de estudo avaliadas, o que reforça a

viabilidade do método de fluorescência *in vivo* para detecção, ainda que realizada em seu estágio inicial de florescimento do fitoplâncton.

A geoestatística se mostrou eficaz na interpolação dos dados de clorofila-a, permitindo a interpretação do comportamento espacial dos dados e, conseqüentemente, a inferência da concentração em locais não amostrados. No mais, a possibilidade de gerar uma representação espacial da variância do erro, viabilizada pela krigagem ordinária, permite verificar quais regiões resultaram em uma estimativa mais confiável.

Sobre a utilização das redes neurais artificiais, verificou-se a necessidade de tratar os dados espectrais de entrada, de acordo com as características da inferência que se pretende realizar. A utilização de dados não diretamente relacionados às feições espectrais da clorofila mostrou prejudicar o desempenho da rede, como foi verificado utilizando todas as bandas espectrais do sensor WorldView-2. De qualquer forma, quando se conhece o fenômeno avaliado, é possível treinar uma RNA que consiga capturar mesmo as pequenas variações.

Referências Bibliográficas

- Arraut, E. M.; Ruddorf, C. de M.; Barbosa, C. C. F.; Carvalho, J. C.; Pereira Filho, W.; Novo, E. M. L. M. 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, 12, 2005, Goiânia, **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 2447-2454.
- Camargo, E. C. G. Geoestatística: fundamentos e aplicações. In: Câmara Neto, G., et al. **Geoprocessamento: teoria e aplicações**. São José dos Campos: INPE, 2000. p. 12.1-12.25. (INPE-8083-PRE/3898).
- Felgueras, C. A. **Modelagem Ambiental com Tratamento de Incertezas em Sistemas de Informação Geográfica: O Paradigma Geoestatístico por Indicação**. 1999. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999.
- Ferreira, M. S. **Inferência espacial da clorofila-a por redes neurais artificiais aplicadas a imagens multiespectrais e mediadas tomadas *in situ***. 2011. Dissertação (Mestrado em Ciências Cartográficas) – Unesp, Presidente Prudente, 2011.
- Fisher et al. Java Neural Network Simulator: **User Manual, Version 1.1**. Tübingen: University of Tübingen, 2001.
- Holler, F. J.; Skoog, D. A.; Crouch, S. R. **Princípios de análise instrumental**. 6º Ed. Porto Alegre: Bookman, 2009.
- Jensen, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 604 p.
- Kirk, J. T.O. **Light and photosynthesis in aquatic ecosystems**. Cambridge: University Press, 1994.
- Landim, P. M. B. **Análise estatística de dados geológicos**. São Paulo: Fundação Editora da UNESP, 1998.
- Lippmann R. P.. **An introduction to computing with neural nets**. **IEEE ASSP Magazine**, v.4, p.4-22, 1987.
- Nakaema, M. K. K.; Sanches, R. **Fluorometria no domínio da frequência**. São Carlos: Química Nova, 1999.
- SCHALLES, J. F.; YACOBI, Y. Z. Remote detection and seasonal patterns of phycocyanin, carotenoid and chlorophyll pigments in eutrophic waters. *Archiv fur Hydrobiologie Special Issues Advances in Limnology*, 55, 153–168, 2000.
- Turner Designs. **Fluorometer Calibration for *in vivo* detection of Cyanobacterial Pigments**. 2004. Disponível em: <http://www.turnerdesigns.com/t2/doc/appnotes/cyano.html>. Acesso em: 15 de março de 2011
- Vincent, R. K.; Qin, X.; McKay, M.; Miner, J.; Czajkowski, K.; Savino, J.; Bridgeman, T. Phycocyanin detection from LANDSAT TM data for mapping cyanobacterial blooms in Lake Erie. **Remote Sensing of Environment**, v. 89, p. 361-368, 2004.
- Utsumi, A. G. **Inferência espacial de cianobactérias a partir da fluorescência *in vivo* do pigmento ficocianina**. 2012. Dissertação (Mestrado em Ciências Cartográficas) – Unesp, Presidente Prudente, 2012.
- Zell, A. **SNNS: Stuttgart Neural Network Simulator**. User Manual, Version 4.1. Stuttgart, University of Stuttgart, 1995 (Report No. 6/95).