Mapeamento da distribuição espacial de Sólidos Suspensos Totais via inferência estatística versus imagem orbital no reservatório de Barra Bonita

Nariane Bernardo¹

¹Universidade Estadual de São Paulo - UNESP/FCT Caixa Postal 305 - 19060-900 – Presidente Prudente - SP, Brasil narianebernardo@gmail.com.br

Abstract. Remote sensing data is an economic approach used for monitoring coastal and inland waters, but the estimates from satellite data are related to the results obtained by atmospheric correction applications. For testing the better approach to estimate total suspended solids (TSS) in Barra Bonita Hydroelectric Reservoir (located in São Paulo State, Brazil), the main goal of this paper was compared two remote-sensed pproaches: the traditional method using *Operational Land Imager* (OLI) atmospherically corrected data and *in situ* radiometric data spatialized by geostatistical method (Ordinary Kriging). To estimate TSS concentrations either via OLI or Ordinary Kriging, a bio-optical model was establish using *in situ* measurements. The best bio-optical model, using linear fit and the Green OLI band, was applied to two images (from Kriging and from OLI atmospherically corrected). The reference data used for comparison among the approaches were *in situ* TSS concentrations spatialized with Ordinary Kriging and assessed by Kernel Estimator map. To use OLI image, several atmospheric correction methods were tested and the lowest SST estimate error was obtained using the Fast Line-of-sight Atmospheric Analysis of Hypercubes (FLAASH) method. The results indicated an overestimation of SST concentrations when OLI image was used, which can be caused by atmospheric correction errors. The best estimates were provide by using Ordinary Kriging of remote sensing reflectance (R_{rs}) from fieldwork, which can be justified due to use *in situ* measurements instead of modelling the atmospheric effects, as made at OLI image.

Palavras-chave: Geoprocessamento, Krigeagem, Bio-óptica, Algoritmos empíricos.

1. Introdução

O uso de dados remotos para a investigação de fenômenos geográficos permite compreender a natureza do fenômeno e sua relação com as diversas evidências espacialmente distribuídas. Em sistemas aquáticos, a abordagem remota possibilita a visão integrada de fenômenos espaciais por meio da aplicação de imagens de sensores remotos na avaliação da qualidade da água; além de apresentar vantagens econômicas, como redução de custos com coletas *in situ*, e garantir a cobertura temporal e espacial dos dados em decorrência do tempo de revisita do sensor (MATTHEWS, 2011; PALMER *et al.*, 2015).

A aplicabilidade de imagens orbitais obtidas por sensores passivos é dependente das condições climatológicas no momento de sua aquisição, uma vez que o dado radiométrico registrado pelos sensores é resultante do balanço radiométrico do sinal proveniente dos alvos e da radiação eletromagnética (REM) espalhada pelos gases e aerossóis presentes na atmosfera (BUKATA *et al.*, 1995; KUTSER *et al.*, 2005).

Os efeitos de espalhamento e absorção podem ser minimizados por meio de técnicas de correção atmosférica aplicadas às imagens. Entretanto, mesmo que haja a modelagem desses efeitos, ainda é possível permanecer alguns resíduos do processo de correção. Em contrapartida, dados que tenham sido remotamente obtidos durante campanhas de campo apresentam uma reduzida interferência dos componentes atmosféricos devido à aquisição próxima ao alvo de

interesse, e portanto, podem estimar parâmetros da qualidade da água com maior nível de confiabilidade.

O objetivo desse trabalho foi avaliar a distribuição espacial de Sólidos Suspensos Totais (SST) no reservatório hidrelétrico de Barra Bonita (BB), localizado no Rio Tietê (em São Paulo) por meio de duas metodologias distintas: 1) dados radiométricos orbitais de imagem de sensoriamento remoto após correção atmosférica e; 2) dados radiométricos obtidos *in situ* especializados por meio de método geoestatístico. As abordagens foram comparadas de forma a avaliar a confiabilidade do mapa das estimativas de SST produzidas por cada enfoque.

Portanto, avaliar a distribuição espacial de SST no reservatório permite compreender quais as regiões de elevadas concentrações desse parâmetro e identificar possíveis atividades associadas à tais ocorrências, desde que as análises da distribuição espacial de SST sejam realizadas de forma concomitante a avaliação dos mapas de uso e cobertura do solo na área de estudo.

2. Reservatório Hidrelétrico de Barra Bonita

O reservatório hidrelétrico de Barra Bonita (BB) (22°36'50,12"S; 48°20'54,57"O), localizado no Rio Tietê - estado de São Paulo (Figura 1), é o primeiro reservatório de uma série em cascata com uma área alagada de aproximadamente 325 km². Por ser o primeiro reservatório da série e devido à sua proximidade à região metropolitana de São Paulo, esse sistema aquático tende a apresentar maiores níveis de concentração de SST e outros nutrientes quando comparados aos reservatórios à jusante. Ao longo de sua operação, o reservatório hidrelétrico de BB foi caracterizado quanto às suas variáveis físico-químicas e limnológicas, sendo muitas vezes classificado como um ambiente hipereutrófico (Alcântara et al., 2016; Watanabe *et al.*, 2015).



Figura 1. Localização da área de estudo (a) Brasil com destaque para o estado de São Paulo; (b) Rio Tietê com uma série de reservatórios em cascata da montante (Barra Bonita) à jusante (Três Irmãos); (c) e (d) representam os 19 pontos amostrais para a primeira e segunda campanha de campo, respectivamente.

As elevadas cargas de nutrientes e SST ocasionam a redução da zona eufótica do reservatório, implicam na degradação da qualidade da água em decorrência da adsorção de herbicidas e pesticidas pelas partículas suspensas, e podem diminuir a cota do reservatório e consequentemente, reduzir o seu potencial hidrelétrico, em decorrência do processo de sedimentação de tais partículas ao longo do tempo (Bilota e Brazier, 2008).

3. Materiais e Métodos

As etapas desenvolvidas nesse trabalho foram realizadas conforme o modelo de dados geográficos OMT-G, expresso na Figura 2. O uso deste modelo permitiu organizar a estrutura dos dados geográficos utilizados e as aplicações desenvolvidas para obtenção do mapa de distribuição espacial de SST. O uso do diagrama permite o incremento da compreensão semântica do modelo de dados geográficos (Borges *et al.*, 2005), de forma que representações reducionistas desses dados não interfiram na replicabilidade da metodologia utilizada.



Figura 2. Diagrama OMT-G da metodologia utilizada.

3.1 Coletas in situ

As campanhas para amostragem *in situ* de grandezas radiométricas e concentrações de SST foram realizadas em dois períodos: entre os dias 05 a 08 de Maio de 2014 e dias 13 a 16 de Outubro de 2014, ambos com 19 pontos amostrais georreferenciados no Datum WGS84 (vide Figura 1). A definição do esquema amostral seguiu a metodologia exposta por Rodrigues *et al.* (2015).

3.1.1 Dados Radiométricos

Dados radiométricos foram coletados em termos de valores de radiância (em W.m⁻².sr⁻¹) e irradiância (W.m⁻²) por meio dos sensores da marca RAMSES TriOS, conforme protocolos estabelecidos por Mobley (2003), durante o período das 10:00 às 15:00 do horário local (GMT-3).

Os dados radiométricos hiperespectrais amostrados permitiram o cálculo da Reflectância de Sensoriamento Remoto (R_{rs} – Equação 1) conforme Mobley (2003). Uma vez calculados os valores de R_{rs} , esses foram simulados (reamostrados espectralmente para R_{rs_r}) para as bandas do sensor *Operational Land Imager* (OLI) a bordo do Landsat-8, conforme a Equação 2.

$$R_{rs}(\theta,\varphi,\lambda,0^{+}) = \frac{L_{t}(\theta,\varphi,\lambda,0^{+}) - 0.028 \times Lc\acute{eu}(\theta,\varphi,\lambda,0^{+})}{E_{d}(\theta,\varphi,\lambda,0^{+})}$$
(1)

$$R_{\rm rs_s}(\theta,\varphi,\lambda_{\rm i},0^{+}) = \frac{\sum_{\lambda} R_{\rm rs}(\theta,\varphi,\lambda,0^{+}) \times S(\lambda)}{\sum_{\lambda} S(\lambda)}$$
(2)

Onde $L_t(\theta, \varphi, \lambda, 0^+)$ representa a radiância total medida pelo sensor; $L_{c\acute{e}u}(\theta, \varphi, \lambda, 0^+)$ é a radiância difusa, $E_d(0+)$ é a irradiância descendente, e $S(\lambda)$ é a função resposta espectral do sensor OLI para cada banda (Barsi *et al.*, 2014).

3.1.2 Concentrações de SST

As concentrações de SST foram estabelecidas conforme protocolo da APHA (*American Public Health Association*, 1998). Filtros de fibra de vidro Whatman 47 mm foram calcinados (470°C na mufla) e pesados (P0) após terem atingido temperatura ambiente no dessecador. Os filtros foram identificados (peso e ponto amostral) e foram utilizados no processo de filtragem das amostras de água coletadas *in situ*.

Os filtros contendo material particulado foram colocados na estufa por 12 horas (temperatura entre 103°C e 105°C) para evaporar toda a água que pudesse estar retida nos póros. Após alcançaram a temperatura ambiente, os filtros foram novamente pesados em balança semi-analítica de alta precisão (P1). A diferença entre P1 e P0, dividida pelo volume da amostra de água filtrada, determinou a concentração de SST em mg.L⁻¹.

3.2 Superfície de Referência de SST via Krigeagem

Para avaliação das abordagens utilizadas na estimativa de SST foi necessário o estabelecimento de uma superfície de referência. Desta forma, as concentrações *in situ* de SST dos 19 pontos amostrais foram utilizadas como dados de entrada para interpolação via Krigeagem Ordinária, o qual considera que a média do fenômeno é constante e portanto, é um fenômeno estacionário de segunda ordem (variância dos dados dependerá apenas da distância entre dois pontos).

A principal vantagem do método de Krigeagem em relação à outros métodos de interpolação é a estimativa de uma matriz de covariância espacial que determina os pesos atribuídos às diferentes amostras, a análise quanto à redundância dos dados, a vizinhança que será considerada no processo de inferência, e as variâncias dos resultados obtidos (Camargo *et al.*, 2004).

O mapa de referência de SST foi estabelecido conforme as etapas previstas na Krigeagem: análise exploratória dos dados; análise estrutural por meio do cálculo e estabelecimento do modelo do semivariograma experimental; e inferência por meio de Krigeagem, ou seja, interpolação estatística.

A análise exploratória dos dados de SST para obtenção das estatísticas univariadas se encontra na Figura 3, sendo possível observar que o coeficiente de assimetria foi relativamente pequeno, e os valores de média e mediana foram similares, o que indica a distribuição normal do conjunto de dados. Para obtenção de maiores informações, também foram averiguadas as propriedades de normalidade do conjunto de dados (Figura 4).

	E S T A T Í S T I C A S: 19_amostras_TSM_out14
=>	Número de Pontos 19
=>	Número de Pontos Válidos 19
=>	Média 20.81052640
=>	Variância 22.69673186
=>	Desvio Padrão 4.76410872
=>	Coeficiente de Variação 0.22892783
=>	Coeficiente de Assimétria0.25173166
=>	Coeficiente de Curtose3.77646786
=>	Valor Mínimo 10.80000019
=>	Quartil Inferior 18.79999924
=>	Mediana 21.00000000
=>	Quartil Superior 22.90000153
=>	Valor Máximo 32.79999924

Figura 3. Análise exploratória das concentrações de TSM para área de estudo.



Figura 4. Análise da normalidade dos dados por meio do diagrama de frequências (esquerda) e gráfico de probabilidade normal (direita).

Considerando as semelhanças do histograma de frequência com a curva de distribuição Gaussiana (Curva de distribuição e Gráfico de normalidade na Figura 4-a) e a proximidade dos valores de média e mediana (Figura 3), é possível assumir que os valores de SST apresentam uma distribuição de probabilidade normal.

A análise estrutural dos dados permite investigar a variabilidade e sua dependência espacial por meio da análise de covariância entre pares de amostras considerando a direção (ângulos) e a distância (representada por h) entre eles. Se a dependência espacial está em função do ângulo e de h, o fenômeno é considerado anisotrópico; se a dependência é a mesma em todas as direções variando apenas em função de h, o fenômeno é caracterizado como isotrópico (Camargo *et al.*, 2004).

Devido ao número restrito de amostras distribuídas na área de estudo (n = 19), identificar o fenômeno de anisotropia não foi trivial e portanto foi assumido que o fenômeno ocorre de maneira estacionária (média e variância constantes sem tendência) e isotrópica (covariância dos dados dependem apenas da distância entre os pontos e não da sua direção).

A partir dessas considerações foi gerado um semivariograma experimental omnidirecional $(\gamma(h))$, com tolerância angular de 90° (Figura 5-a). O estabelecimento do semivariograma experimental (Equação 3) é dado em função do vetor de distância (*h*) e considera todos os pares de amostras ($z(x_i)$ e $z(x_i+h)$) separados por *h*.

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum \left[z(x_i) - z(x_i + h) \right]^2$$
(3)

Onde o valor de N(h) representa a quantidade de pares que foram utilizadas na análise, separados por h, $z(x_i)$ é o valor de SST na posição x_i e $z(x_i+h)$ é o valor de SST na posição (x_i+h) .

Em decorrência das hipóteses assumidas (estacionariedade e isotropia), o semivariograma deve apresentar uma configuração similar à Figura 5 (b), onde o valor absoluto da diferença entre duas amostras deve crescer conforme o aumento da distância entre elas, até que os efeitos locais (interferência de um ponto sobre outro) não tenha mais influência (não apresente variação). Portanto, o uso do semivariograma e de seus respectivos componentes (alcance, patamar, e efeito pepita – Figura 5-b) representam a estrutura dos dados formalizada por meio do semivariograma.



Figura 5. (a) Semivariograma das amostras in situ de SST, para número de lags = 4; incremento = 3590 metros e tolerância = 1560 m. (b) Comportamento de semivariograma esperado devido ao princípio de estacionariedade.

A determinação do semivariograma presume que seja ajustado um modelo representativo da tendência de γ em relação à h. O processo de ajuste do modelo é feito de forma iterativa, já que depende da avaliação do intérprete quanto ao ajuste e da equação do modelo teórico. Testes devem ser realizados até que se modele satisfatoriamente as relações estabelecidas pelo semivariograma.

Os três modelos testados - esférico, exponencial e gaussiano, foram avaliados conforme os parâmetros de ajuste dispostos na Tabela 1.

Tabela 1. Parametros dos modelos de ajuste do semivariograma de SST						
Modelo	Akaike	Akaike Pepita Contribui		io Alcance (em m)		
Esférico	-40,84	3,281	22,853	11196,659		
Exponencial	-31,338	1,118	25,663	14352,257		
Gaussiano	-42,561	6,096	20,087	9368,392		

aar

Por meio da análise de menor valor de Akaike, melhor razão entre o efeito pepita e a contribuição e avaliação do alcance em relação à área do projeto desenvolvido, foi verificado que o melhor modelo de ajuste do semivariograma foi esférico, expresso pelo sistema de Equações 4. Algebricamente, o semivariograma pôde ser descrito pela Equação 5.

$$Sph[|h|] = \begin{cases} 0, |h| = 0\\ 1.5 \times \left(\frac{|h|}{11196,66}\right) - 0.5 \times \left(\frac{|h|}{11196,66}\right)^3, 0 \le |h| \le 11196,66 \end{cases}$$
(4)

$$\hat{\gamma} = C_0 + C_1 \times Sph(\frac{h}{a}) = 3,281 + 22,853 \times \left[Sph(\frac{h}{9368,392})\right]$$
(5)

A adequabilidade do modelo esférico para posterior interpolação foi avaliada por meio da análise estatística dos erros de estimativa (Figura 6 - a, b). A distribuição dos erros mostrou que os erros obtidos foram aceitáveis e o modelo escolhido foi adequado.



Figura 6. Análise dos erros obtidos por uso de modelo esférico para semivariograma das amostras de SST.

3.3 Estimador de Kernel

O uso do estimador de Kernel permitiu avaliar se as incertezas das estimativas da superfície de referência de SST estavam condizentes com a taxa de amostragem da área de estudo.

A análise do comportamento de padrões de pontos amostrais *in situ* pode ser realizada por meio de uma função de intensidade amostral do fenômeno. Para tanto, uma função bidimensional pode ser ajustada sobre as amostras, de forma que seja gerada uma superfície proporcional à intensidade de amostras em uma unidade de área. O princípio é realizar uma contagem de pontos localizados dentro de uma região de influência, ponderando-os pela distância de cada um dos pontos à uma localização de interesse. O cálculo da função da intensidade de pontos é dada pela Equação 6.

$$\hat{\lambda} = \frac{1}{\tau^2} \sum_{i=1}^n k(\frac{d(u_i, u)}{\tau}), \quad d(u_i, u) \le \tau$$
(6)

Onde $\hat{\lambda}$ é o estimador de Kernel calculado em função de dois parâmetros: raio de influência (τ) que define qual será a vizinhança de pontos (u_i) do ponto a ser interpolado (u); e a função de suavização "k", a qual controla a suavidade da superfície de intensidade. Para o trabalho, $\tau = D/2$, onde D é o valor médio das distâncias entre os pontos (D), resultando em $\tau = 1600$ metros de forma que os valores de τ não fossem pequenos para gerar uma superfície descontínua e nem grande demais para gerar uma superfície demasiadamente suavizada. A função de suavização "k" utilizada no processo de estimação de Kernel foi uma função quártica descrita em Silverman (1986).

A principal vantagem destes estimadores é supor que o fenômeno possui uma densidade de variação suavizada na superfície em decorrência de uma interpolação sofisticada que não requer a parametrização de um semivariograma (Camargo *et al.*, 2004). É necessário porém, saber o estimador é extremamente sensível ao raio de busca das amostras (τ), sendo este o principal parâmetro a ser testado. Após estabelecido o mapa de Kernel, o produto foi fatiado em intervalos iguais a fim de aprimorar a visualização dos resultados.

3.4 Modelo de estimativa de SST

O modelo para estimar as concentrações de SST no reservatório de BB foi estabelecido de forma empírica utilizando as medidas *in situ*, ou seja, por meio da análise das correlações estatísticas entre R_{rs_r} e concentração de SST. Os modelos, linear, exponencial e quadrático, foram estabelecidos apenas para as bandas do verde (centrada em 561,4 nm), vermelho (centrada em 654,6 nm) e infravermelho (centrada em 864,7 nm), pois as bandas da região do azul são intensamente afetadas pelos efeitos de espalhamento de Rayleigh. Além disso, menores comprimentos de onda apresentam elevada absorção de outros componentes opticamente ativos – CDOM (Matéria Orgânica Dissolvida Colorida) e Clorofila-*a* (Kirk, 1994).

Os pontos amostrais das duas campanhas de campo compuseram um único conjunto de dados, o qual foi subdividido aleatoriamente em dois subconjuntos – um para calibração e outro para validação do modelo.

Os resultados das estimativas foram avaliadas a partir do cálculo da Raiz do Erro Médio Quadrático (RMSE, em inglês *Root Mean Squared Error*), Erro Médio Absoluto (MAPE, em inglês *Mean Absolute Percentage Error*) e Viés (ou Bias), calculados conforme as equações 7, 8 e 9.

RMSE =
$$\sqrt{\frac{\sum_{i=1}^{n} (x_i - x_{true})^2}{n}} \times \frac{100 \times n}{\sum_{i=1}^{n} x_{true}}$$
 (7)

$$MAPE = \frac{1}{n} \times \sum_{i=1}^{n} \left| \frac{x_i - x_{true}}{x_{true}} \right| \times 100$$
(8)

$$\operatorname{Bias} = \frac{1}{n} \times \sum_{i=1}^{n} \left(x_{i} - x_{\operatorname{true}} \right)$$
⁽⁹⁾

Onde x_i é o valor da concentração de SST estimado pelo modelo, e x_{true} é o valor medido *in situ*, sendo i a primeira e n a última amostra medida em campo.

Os resultados da validação dos modelos se encontram na Tabela 2. A variância dos resíduos foi analisada conforme teste estatístico F. Foi possível averiguar que o tipo de ajuste (linear ou quadrático) e a banda utilizada (verde – OLI3, vermelho – OLI4, ou infravermelho – OLI5) não alteram significativamente as variâncias dos erros obtidos. Portanto, os modelos linear e quadrático foram aplicados às bandas da imagem OLI atmosfericamente corrigida.

Tabela 2. Modelos de SST obtidos por meio de ajuste linear, exponencial e quadrático, com respectivos coeficientes e erros – RMSE (em %), MAPE (em %), e Bias (em mg L⁻¹), onde modelo linear : SST = $a \times R_{rs_r} + b$; modelo exponencial: SST = $y = a \times exp(b \times R_{rs_r})$; e modelo quadrático: SST = $a \times (R_{rs^2}) + b \times R_{rs_r} + c$.

BANDA DO OLI	AJUSTE	<i>p</i> -valor	а	b	с	RMSE (%)	MAPE (%)	Bias (mg L ⁻¹)
	Linear	< 0.01	1742.71	-5.64	-	25.44	25.19	2.37
OI 13	Exponencial	< 0.01	3.95	105.71	-	28.45	28.19	3.19
OLIS	Quadrático	< 0.01	-84075.3	3779.97	- 16.77	25.87	35.84	1.32
	Linear	< 0.01	3416.03	-8.37	-	23.88	24.29	1.67
OLI4	Exponencial	< 0.01	2.92	10.42	-	31.52	23.91	3.12
	Quadrático	< 0.01	14325.66	3223.76	-7.78	24.09	23.93	1.73
	Linear	< 0.01	3952.25	2.69	-	20.29	23.27	0.73
OLI5	Exponencial	< 0.01	6.93	224.42	-	26.35	33.19	1.06
	Quadrático	< 0.01	73576.96	3542.81	3.34	21.25	23.48	0.81

3.5 Processamento da imagem OLI

3.5.1 Correção atmosférica

A imagem do sensor OLI utilizada para aplicação do modelo foi tomada no dia 13 de outubro de 2014 (órbita/ponto 220/76). A imagem foi calibrada radiometricamente, ou seja, foi realizada uma transformação dos valores de número digital para valores de reflectância de topo da atmosfera (R_{TOA}) por meio dos fatores de escala disponibilizados nos metadados da imagem.

Para a obtenção da imagem de Reflectância de superfície (R_{SUP}), foram testados cinco métodos de correção atmosférica - *Dark Object Subctraction* (DOS – Chaves, 1988), *Quick Atmospheric Correction* (QUAC- Bernstein, 2005), *Fast Line-of-sight Atmospheric Analysis of Hypercubes* (FLAASH- Adler-Golden et al, 1999), *Atmospheric Correction for OLI 'lite'* (ACOLITE-Vanhellemont e Ruddick, 2015), e o produto já disponibilizado em R_{SUP} - *Provisional Landsat-8 Surface Reflectance Algorithm* (L8SR-USGS, 2015).

O cálculo do espalhamento atmosférico presente na cena, na maioria das vezes, consideram algumas propriedades da própria imagem. No caso do método DOS, foi avaliado o histograma de frequências da cena e o mínimo valor de cada banda identificado no histograma foi subtraído da respectiva banda por álgebra de mapas (operação pontual). No método QUAC, a ideia é semelhante ao método DOS: ao invés de utilizar o histograma da imagem toda são selecionadas regiões de diferentes respostas espectrais cujo espectro médio é considerado como um "pixel puro". O resultado desse método é dado em um fator de escala de 10000, e portanto, uma álgebra de mapas foi aplicada para retornar aos valores de R_{SUP} .

A contribuição de aerossóis do método FLAASH foi determinada por meio do modelo Kaufman-Tanre (K-T) estabelecido no modelo de Kaufman *et al.* (1997), onde um pixel escuro é selecionado a partir do resultado da razão de bandas apropriada. Neste trabalho os pixels selecionados foram aqueles cuja razão entre as bandas mais próximas de 660 nm e 2100 nm resultaram em valores próximos à 0,45.

O método ACOLITE faz uso de uma operação pixel-a-pixel para realizar a estimativa da contribuição dos aerossóis na cena, mas também é possível admitir um valor médio para a toda a cena. Nesse estudo, o estabelecimento da contribuição dos aerossóis foi calculado por meio da

razão entre as duas bandas do SWIR do satélite OLI e o valor obtido médio foi considerado constante para toda a cena, de forma que os valores de R_{SUP} obtidos não fossem negativos (Vanhellemont e Ruddick, 2015).

Para aplicação do modelo, foi realizada a conversão da imagem de R_{SUP} para R_{rs} conforme metodologia exposta em Moses et al. (2012). Cada imagem resultante da correção atmosférica foi submetida à uma operação pontual via álgebra de mapas (divisão de cada pixel da cena por 3,1415926).

3.5.2 Estimativa das concentrações de SST via imagem OLI

A aplicação do modelo na imagem atmosfericamente corrigida permitiu avaliar qual o método de correção atmosférica seria capaz de produzir as estimativas das concentrações de SST com menor erro. A validação dos métodos foi realizada por meio da comparação dos valores obtidos via imagem e *in situ*.

Os gráficos, representados na Figura 7, mostram a distribuição do erro dos modelos linear e quadrático de estimativa de SST (Tabela 2) ao serem aplicados nas respectivas bandas do verde, vermelho e infravermelho do sensor OLI posteriormente às correções atmosféricas testadas.



Figura 7. RMSE de SST dos modelos linear e quadrático aplicados nas bandas do verde, vermelho e infravermelho para cada um dos métodos de correção atmosférica.

Um dos menores erros obtidos foi por meio da aplicação do modelo da banda do verde (Equação 10) na imagem corrigida pelo método FLAASH. Erros pequenos também foram encontrados no produto de R_{SUP} disponibilizada pela *United States Geological Survey* (earthexplorer.usgs.gov), contudo, as imagens ainda apresentam problemas na correção atmosférica (USGS, 2015).

$$SST = 1742,71 \times (OLI3) - 5,42$$
 (10)

3.6 Estimativa das concentrações de SST via krigeagem de Rrs_r

A análise de erros dos modelos bio-ópticos aplicados nas imagens atmosfericamente corrigidas (Figura 3) permitiu observar que o menor erro obtido a partir das estimativas via imagem OLI foi por meio do uso da banda do verde e modelo linear. Contudo, mesmo que os métodos de correção atmosférica modelem os efeitos de absorção de gases e espalhamento das partículas, alguns ruídos

do processo correção podem permanecer devido à adaptação dos dados de entrada requeridos desses métodos.

Os valores de R_{rs_r} (reamostrados) para a banda verde do OLI foram interpoladas pelo método da Krigeagem ordinária, resultando em uma superfície de R_{rs_r} , sobre a qual foi aplicado o modelo linear para estimativas de SST (Equação 10), obtendo assim uma nova distribuição espacial de SST. O uso apenas da banda verde na krigeagem foi para gerar resultados comparáveis às estimativas da imagem OLI.

Como o cálculo da R_{rs_r} foi feito a partir das medidas realizadas *in situ*, é esperado que esses resultados não sejam diretamente influenciados pelas condições atmosféricas, como o que ocorre no caso de imagens orbitais. Os passos da krigeagem de R_{rs_r} foram os mesmos que para a krigeagem de SST: análise exploratória dos dados; análise estrutural; e inferência por meio de Krigeagem, ou seja, interpolação estatística.

A análise exploratória realizada para o conjunto de dados da R_{rs_r} da banda verde do OLI (Figura 8) mostram a proximidade dos valores de média e mediana, bem como a proximidade da distribuição frequência próxima à Curva Gaussiana (Figura 9). Essas características garantem assumir que os valores de R_{rs_r} apresentam uma distribuição normal. Ressalta-se que devido à grandeza das medidas radiométricas e para garantir consistência da aplicabilidade do método de krigeagem, os dados foram reescalonados por um fator de escala de 1000.

E S T A T Í S T I C A S: 19_amostras_1000_Rrs_B3

=>	Número de Pontos 19
=>	Número de Pontos Válidos 19
=>	Média 15.26285463
=>	Variância 8.05968326
=>	Desvio Padrão 2.83895813
=>	Coeficiente de Variação 0.18600440
=>	Coeficiente de Assimétria0.43233160
=>	Coeficiente de Curtose2.15815125
=>	Valor Mínimo 9.93011284
=>	Quartil Inferior 13.89662170
=>	Mediana 16.04602432
=>	Quartil_Superior 17.24417496
=>-	Valor Máximo 19.90287590

Figura 8. Análise exploratória dos valores de R_{rs_r} da banda verde do OLI na área de estudo.



Figura 9. Análise da normalidade dos dados de R_{rs_r} por meio do diagrama de frequências (esquerda) e gráfico de probabilidade normal (direita).

A avaliação da correlação espacial das amostras de R_{rs_r} foi realizada por meio do uso do semivariograma. Assim como nas amostras de SST, as amostras de R_{rs_r} (n = 19) não possibilitaram analisar o fenômeno de anisotropia. Portanto, todas as análises foram realizadas com as mesmas

considerações realizadas para SST – o fenômeno foi considerado estacionário, isotrópico e ominidirecional. O semivariograma para a variável R_{rs_r} se encontra na Figura 10.



Figura 10. (a) Semivariograma das amostras de R_{rs_r} da banda verde do OLI, para número de lags = 4; incremento = 2650 metros e tolerância = 1640 m. (b) Comportamento de semivariograma esperado devido ao princípio de estacionariedade.

O ajuste dos modelos do semivariograma (Figura 10) foram avaliados conforme o valor do patamar ser próximo ao valor da variância, o valor do alcance ser condizente com os limites estabelecidos no projeto, menor valor de efeito pepita de forma que a contribuição do modelo fosse maior, e o menor valor da estatística Akaike (teste estatístico para ajuste de modelo). Os melhores ajustes para cada um dos modelos – esférico, exponencial e Gaussiano, estão na Tabela 3.

Modelo	Akaike	Pepita	Contribuição	Alcance (em m)	
Esférico	-21,560	0,259	6,927	8493,094	
Exponencial	-23,901	-2,065	9,268	7642,884	
Gaussiano	-20,790	1,194	5,730	6439,786	

Tabela 3. Parâmetros dos modelos de ajuste do semivariograma de R_{rs_r} da banda verde do OLL

A partir dos resultados obtidos foi possível estabelecer que o melhor modelo de ajuste ao semivariograma foi o modelo esférico, pois apresentou a melhor razão entre os parâmetros pepita e contribuição, o que indica que o modelo conseguiu contribuir para a modelagem da dependência espacial e consequentemente, reduzir o efeito dos ruídos aleatórios das medidas expressos no efeito pepita. Além disso, os erros foram avaliados conforme sua distribuição e coeficiente de correlação de Pearson (*r*), com r = 0,40 (Figura 11) mostraram a adequabilidade do modelo.



Figura 11. Distribuição espacial dos erros (esquerda) e avaliação das estimativas (direita).

Após a modelagem do semivariograma, a superfície de R_{rs_r} gerada foi submetida à aplicação do modelo linear de estimativa de SST, resultando na distribuição espacial de SST via krigeagem da R_{rs_r} da banda verde.

Os resultados das estimativas via banda verde da imagem OLI (aqui referenciado como estimativa via imagem) ou via Krigeagem de R_{rs_r} (aqui referenciado como via Krigeagem) foram avaliados por meio de álgebra de mapas entre os valores de referência (valores de SST interpolados pela Krigeagem – item 3.2) e os mapas de estimativas de SST (via imagem e via Krigeagem da R_{rs_r}).

4. Resultados

4.1 Distribuição Espacial de SST amostrado in situ

A distribuição espacial de SST medidos *in situ* obtida via Krigeagem, modelo esférico, está disposta na Figura 12(a), enquanto que as variâncias das estimativas e os valores de Kernel se encontram na Figura 12 (b) e (c), respectivamente.



Figura 12. (a)Distribuição espacial via Krigeagem Ordinária das concentrações de SST amostradas *in situ*; (b)Variância das estimativas das concentrações de SST; (c) Dependência espacial das amostras *in situ* definida por Kernel.

4.2 Modelagem espacial de SST: Krigeagem versus imagem

A distribuição espacial de SST via Krigeagem e via imagem foi obtida pela aplicação do modelo linear (Equação 10) nas cenas obtidas. A R_{rs_r} da banda verde do OLI (amostrada *in situ*) especializada via Krigeagem, permitiu realizar as estimativas de SST (Figura 13-a). Para avaliar a qualidade das estimativas, foi realizada a álgebra de mapas entre os dados de referência (Figura 12-a) e as estimativas via Krigeagem (Figura 13-a). O resultado álgebra de mapas se encontra na Figura 13 (c)

De forma análoga, a imagem OLI atmosfericamente corrigida permitiu estimar os valores de SST (Figura 13 –b) por meio da aplicação do mesmo modelo (Equação 10). O resultado da álgebra de mapas entre a imagem de referência (Figura 12-a) e a imagem de estimativa de SST via imagem (Figura 13-b) pode ser observado na Figura 13 (d).



Figura 13. Distribuição espacial de SST via (a) Krigeagem de R_{rs_r} das amostras *in situ* e (b) banda verde do OLI corrigida atmosfericamente, com respectivos resultados da álgebra de mapas - diferenças entre o dado de referência e estimativas via Krigeagem (c) e via imagem OLI (d). Para melhor visualização, as escalas de cores em (c) e (d) foram especificadas para cada uma das abordagens de distribuição espacial.

As estimativas de SST foram avaliadas quantitativamente por meio do histograma de frequência das diferenças resultantes da álgebra de mapas, o que permitiu verificar que as diferenças entre valores estimados e valores de referência via Krigeagem ficaram entre [-9,8 < SST < 8,5] (Figura 14-a); e via imagem entre [-39,1 < SST < 10,20] (Figura 14 – b).



Figura 14. Diagrama de frequência do resultado da álgebra de mapas entre dados de referência e (a) estimativas de SST via Krigeagem; e (b) estimativas de SST via imagem OLI (banda 3).

5. Discussão

A geoestatística é uma abordagem probabilística que permite avaliar fenômenos de interesse a partir de amostras e suas dependências espaciais, ou seja, amostras mais próximas tendem a estar mais correlacionadas e serem mais parecidas. A ideia principal do método é incorporar o espaço na análise dos dados e comparar os pares de amostras a fim de identificar a dependência espacial e por fim estabelecer, por meio de interpolação, uma superfície para representação de dado fenômeno.

A distribuição espacial via Krigeagem das medidas de SST *in situ* permitiu observar a dinâmica de SST no reservatório de BB e identificou uma região de maior concentração (Figura 12- a1) e regiões de menores concentrações (Figura 12 – a2 e a3). O respectivo mapa de variâncias de SST (Figura 12-b), permitiu identificar regiões cujas estimativas apresentam maior ou menor nível de confiabilidade.

O mapa de confiabilidade dos resultados, expresso como mapa de variâncias das estimativas, é importante para o analista identificar o quão próxima as estimativas resultantes da interpolação estarão dos dados de referência e assim, gerenciar melhor os resultados obtidos pelo processo de inferência. A interpretação do mapa de variância das estimativas indica regiões onde devem ser melhoradas as amostragens, ou seja, em locais onde as incertezas são significativas.

O processo de Krigeagem é um método de interpolação dependente do número de amostras e de sua localização espacial, já que considera o vetor distância na análise estrutural do fenômeno. Portanto, o mapa de densidade de Kernel foi utilizado para testar a hipótese de que as regiões cujos pontos amostrais estão em maior densidade apresentam maior confiabilidade dos resultados obtidos via Krigeagem.

O mapa de Kernel (Figura 12 –c) mostra que na área de estudo há regiões de maior densidade (representadas em azul escuro, na região 1) e menor densidade (azul claro, nas regiões 2 e 3) de amostras. As regiões de maior densidade coincidiram com as regiões de menor variância de estimativa, e as regiões de menor densidade coincidiram com as regiões de maior variância. É importante ressaltar que o mapa de densidade de Kernel tem como limite de estimativa os próprios pontos amostrais, e portanto, não cobrem toda a região do reservatório.

O resultado indica que as regiões de menor amostragem estão sujeitas à maior variância de estimativa de Krigeagem, e portanto, os resultados apresentam menor confiabilidade, como é o caso dos tributários localizados nas regiões 2 e 3 da Figura 12(b). A variância é naturalmente baixa quanto mais próxima aos locais de amostragem, como pode ser observado nas regiões em azul (Figura 12-b). No centroide das amostras a variância é zero pois, o valor do centroide coincide com as amostras de SST medidas *in situ*

Uma vez estabelecido os dados de referência de SST e analisado às suas respectivas variâncias, foi possível avaliar os métodos de distribuição espacial de SST via Krigeagem de R_{rs_r} e via banda verde do OLI (atmosfericamente corrigida).

O mapa de distribuição espacial de SST via Krigeagem (Figura 13–a) garantiu maior suavidade nos resultados de mapeamento, uma vez que considera a correlação espacial entre os pontos. O mapa de distribuição espacial de SST via imagem resultou em regiões de intensa mistura de SST no percurso do reservatório (de jusante – Rios Tietê e Piraciaba) à montante (barragem), o que pode ser justificada pela localização de pixels na imagem que não consideram de forma direta a correlação espacial dos pontos amostrais.

Qualitativamente as estimativas de SST via Krigeagem se assemelharam muito aos dados de referência, uma vez que as elevadas concentrações na região 1 (Figura 12-a) foram bem representadas pela abordagem da Krigeagem (Figura 13-a) mas não foram bem representadas pela estimativas via imagem OLI (Figura 13-b). A região 2 (Figura 12-a) foi melhor representada pela imagem OLI (Figura 13 – b, maiores concentrações em ambos os dados), enquanto que a região 3 (Figura 12-a) e sua heterogeneidade foi melhor representada pelas estimativas via Krigeagem (Figura 13-a).

A álgebra de mapas, resultado da diferença entre os dados de referência e os dados das estimativas, permitiu gerar os histogramas de frequência apresentados na Figura 14. Os resultados expressos nos histogramas mostram que as estimativas via Krigeagem apresentaram um menor intervalo de diferenças do que o histograma resultante via imagem do OLI (banda do verde). Afim de avaliar a adequabilidade das abordagens de estimativa de SST, os valores positivos do histograma de frequência podem ser considerados como subestimativas dos valores de SST e os valores negativos como superestimativas. Os valores próximos à zero são resultantes das estimativas estarem muito próximas aos valores de referência.

A partir dessas considerações é possível observar que o histograma de frequência via imagem OLI (Figura 14-b) é predominantemente negativo e demonstra que as estimativas de SST foram muito maiores que os valores de referência. As superestimativas das concentrações de SST podem ser decorrência dos valores de R_{rs} resultantes da correção atmosférica, que também podemter sido maiores que os valores obtidos *in situ*.

Em contrapartida, a abordagem que apresentou os resultados mais próximos aos valores de referência foram as concentrações de SST obtidas via Krigeagem, uma vez que o diagrama de frequência (Figura 14-a) apresentou um pico máximo próximo à zero. Ainda é possível identificar nesse mesmo diagrama de frequência duas ocorrências significativas- uma subestimativa dos valores de SST próximo à 6,30 mg.L⁻¹ e uma subestimativa próximo à 2,06 mg.L⁻¹, mas ainda assim, menores que a maior frequência identificada próximo à zero.

6. Conclusões

Dados de sensores remotos são fontes de informação geográfica para obtenção de uma visão integrada de processos naturais e antrópicos. A representação de fenômenos em geocampos de radiância ou reflectância como nas imagens permite que as variáveis ambientais sejam caracterizadas temporalmente e espacialmente de forma contínua, identificando as possíveis

relações sazonais. Entretanto, o uso de dados remotos orbitais para estimativas de variáveis biogeoquímicas, como no caso da estimativa das concentrações de SST, depende do uso e manipulação adequada dos dados radiométricos, como a aplicação da correção atmosférica.

Diferentes métodos de correção atmosférica foram testados afim de modelar os efeitos e garantir melhores valores de R_{rs} da imagem OLI. As estimativas de SST via imagem conseguiram mapear a dinâmica espacial da variável, mas quando comparadas aos dados de referência e às estimativas via Krigeagem, não apresentam os melhores resultados.

O resultado das estimativas de SST via Krigeagem de R_{rs_r} ao serem comparados com os valores de referência apresentaram pequenas diferenças (elevada frequência em zero no diagrama de distribuição de frequências). Uma das justificativas para este resultado é que ao interpolar as medidas *in situ* de R_{rs} reamostradas para as bandas do OLI, confirma-se que o efeito atmosférico é praticamente nulo devido à proximidade das medidas radiométricas com o alvo de interesse. As grandes desvantagens do método de interpolação via Krigeagem é a sua relação direta com a quantidade de amostras na área de estudo e os efeitos de anisotropia, os quais não foram modelados neste trabalho devido ao reduzido número de amostras. Entretanto, a variabilidade local e global é modelada de forma não tendenciosa por ser baseada em uma análise estrutural do conjunto de dados.

Os resultados do presente trabalho indicaram que a abordagem probabilística de estimativas, via Krigeagem de R_{rs_r} , foi uma metodologia adequada para o mapeamento da concentração de SST no reservatório de Barra Bonita, proporcionando erros menores que a aplicação do modelo diretamente na imagem atmosfericamente corrigida.

Futuros trabalhos deverão ser desenvolvidos com conjunto de dados amostrais mais robustos, considerando outras campanhas de campo. Além disso, tendo em vista aprimorar o procedimento de validação correção atmosférica, os resultados das correções poderão ainda ser comparados espacialmente com os dados especializados via krigeagem de R_{rs_r} de cada banda (obtidos a partir das medidas *in situ*) ao invés de serem comparados pontualmente (por meio dos pontos de amostragem especializados na imagem atmosfericamente corrigida).

Referências Bilbiográficas

Adler-Golden, S.M. et al, "Atmospheric correction for shortwave spectral imagery based on *MODTRAN4*", In: SPIE Proceedings, Imaging Spectrometry, 3753, 61-69 (1999). [doi:10.1117/12.366315].

Alcântara, E. *et al.*, An investigation into the particle volume scattering function variability in a cascading reservoir system. Modelling Earth Systems and Environment, 2,89, 2016, p.1-5.

APHA, *Standard methods for the examination of water and wastewater*. Washington: American Public Health Association; 1998.

Barsi, J. et al., *"The Spectral Response of the Landsat-8 Operational Land Imager"*, Remote Sens. 6(10): 10232–10251 (2014). [doi:10.3390/rs61010232].

Bernstein, L.S, "Validation of the QUick Atmospheric Correction (QUAC) algorithm for VNIR-SWIR multi- and hyperspectral imagery", In: SPIE Proceedings, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XI, 5806, 668-678 (2005). Bilotta G. S; Brazier R.E. Understanding the influence of suspended solids on water quality and aquatic biota. Water Resource, v. 42, p. 2849–2861, 2008.

Borges, K.A.V., Davis Jr., C.A., Laender, A.H.F. Modelagem Conceitual de Dados Geográficos. In: Casanova, M.A., Câmara, G., Davis Jr., C.A., Queiroz, G.R. (Org.). Banco de Dados Geográficos. Curitiba: Editora MundoGEO, 2005. p.53-92.

BUKATA, R.P. et al. Optical properties and remote sensing of inland and coastal waters, Boca Raton: CRC Press, 1995.

Camargo, E.C.G., Fucks, S.D., Câmara, G. Análise Espacial de Superfícies. In: Análise Espacial de Dados Geográficos. Cap.3. Druck, S.; Carvalho, M.S.; Câmara, G.; Monteiro, A.V.M. (eds). 2005.

Chavez Jr., P.S, "An imporved Dark-Object Substraction Technique for Atmospheric Scattering Correction of Multispectral data", Remote Sens. Environ.,24:459-479 (1988). [doi:10.1016/0034-4257(88)90019-3].

Kutser, T. *et al.* Mapping lake CDOM by satellite remote sensing. Rem. Sens. Environ., v. 94, 535-540, 2005.

Matthews, M. W. A current review of empirical procedures of remote sensing in inland and nearcoastal transitional waters. International Journal of Remote Sensing, v. 32, n. 21, p. 6855–6899, 2011.

Mobley, C. D., "*Estimation of the remote-sensing reflectance from above-surface measurements*", Appl. Opt. 38(36): 7442–7455 (1999). [doi: 10.1364/AO.38007442].

Moses, W. J. et al., "*Estimation of chlorophyll-a concentration in turbid productive waters using airborne hyperspectral data*", Water Res. 46(4): 993–1004 (2012). [doi: 10.1016/j.watres.2011.11.068].

PALMER, S. et al. Remote sensing of inland waters: Challenges, progress and future directions. Rem. Sens. Environ., v. 175, p. 1-8, 2015.

Rodrigues, T.W.P.; Guimarães, U.S.; Rotta, L.H.S.; Watanabe, F.S.Y.; Alcântara, E.; Imai, N.N. Delineamento amostral em reservatórios utilizando imagens Landsat-8/OLI: um estudo de caso no reservatório de Nova Avanhandava (Estado de São Paulo, Brasil). *Boletim de Ciências Geodésicas* 2015.

Silverman, B. W. *Density Estimation for Statistics and Data Analysis*. New York: Chapman and Hall, 1986.

Vanhellemont, Q., and K. Ruddick, "Advantages of high quality SWIR bands for ocean colour processing: Examples from Landsat-8", Remote Sens. Environ.,161: 89–106 (2015). USGS. Product Guide. Provisional Landsat 8 Surface Reflectance Product, v.1.5. 2015.

Watanabe, F.S.Y. et al., "Estimation of Chlorophyll-a Concentration and the Trophic State of Barra Bonita Hydroeletric Reservoir Using OLI/Landsat-8 Images", Int. J. Environ. Public Health, 12, 10391-10417 (2015).