

25. Meio Ambiente

Clorofila-a e turbidez a partir de imagens MODIS: Uma análise comparativa com 15 anos de dados *in situ* para a Represa Billings/SP

Ruiz, Isadora Haddad; Oswaldino, Letícia da Silva; Santos, Milena Ricco; Stoppa, Nathalia Espinossi; Saito, Victor Satoru; Bourscheidt, Vandoir (Orientador)

isadora.rhaddad@gmail.com; leticiaoswaldino@gmail.com; milenarst15@gmail.com; nathaliaespinossi@gmail.com; victor.saito@gmail.com; vandoir@gmail.com; (Orientador)

Universidade Federal de São Carlos

Resumo

A Represa Billings é considerada a maior represa da Região Metropolitana de São Paulo (RMSP), sendo a grande responsável pelo seu abastecimento público. Como a qualidade da sua água é afetada pela expansão urbana e atividades econômicas, há a necessidade de monitoramento contínuo. Dentre as mais promissoras ferramentas de monitoramento, as técnicas de sensoriamento remoto possuem as vantagens de, terem um baixo custo operacional e possibilidade de monitoramento em larga escala. Neste trabalho, utilizamos dados do satélite MODIS a partir da plataforma *Google Earth Engine*, para explicar a variação em dados de clorofila-a e turbidez obtidos *in situ* pela CETESB ao longo de 15 anos (2002-2017), através de regressão múltipla e do método de inteligência artificial *random forest*. Para a clorofila, utilizando técnicas de seleção de modelos, encontramos que o modelo mais simples e com maior explicação inclui as bandas 1, 2, 3, 5 e 7, com um $R^2=0.18$ ($P<0.001$). Com o método *random forest*, obtivemos um $R^2=0.32$ com as mesmas bandas, indicando maior poder de explicação em relação aos modelos lineares. Para a turbidez, ambos os métodos explicaram menos de 5% da variação nos dados, indicando uma fraca relação. Apesar do menor poder explicativo em relação ao encontrado na literatura, possivelmente devido às limitações dos dados da CETESB (como a ausência de informações do horário e ponto exatos da coleta), os modelos foram significativos, reforçando o potencial das informações a partir de satélites como indicativos de qualidade da água.

Palavras-chave: Sensoriamento Remoto, Água, Monitoramento.

Introdução

Elemento fundamental para manutenção da vida no planeta, a água caracteriza-se como recurso natural essencial para sobrevivência de diferentes espécies e desenvolvimento de atividades humanas socioeconômicas (Silva, Dias, Bastos & Silva, 2009). Entretanto, o crescimento demográfico, a intensificação de ações antrópicas decorrente da urbanização como descarga de águas residuais domésticas, de processos industriais (Gemelgo, Sant'Anna, Tucci & Barbosa, 2008) e expansão agropecuária, ou seja, o uso e ocupação da bacia de drenagem, vem comprometendo a qualidade e disponibilidade desse recurso.

Essas atividades estimulam a construção de reservatórios que supram a demanda por abastecimento público (Silva et al., 2009), geração de energia elétrica, irrigação e controle de enchentes. Contudo o represamento de rios por barragens influencia e modifica a dinâmica dos ecossistemas aquáticos, constituindo um ambiente com fluxo de água lenta, longa residência hidráulica e comprimento, com influência no transporte de sedimentos e ciclagem química (Souza, Medeiros, Brandini, & Knoppers, 2011). Resultante a isso, a eutrofização da água se tornou a principal preocupação em ecossistemas aquáticos, e acredita-se que essa seja aumentada devido as

mudanças climáticas (Elliott, Jones & Thackeray, 2006).

A eutrofização, processo onde há estímulo aos produtores primários, fitoplâncton, como respostas ecológicas as cargas de nutrientes (Tundisi, 2001), diminui o oxigênio dissolvido, ocasiona a mortalidade de peixes e aumenta a turbidez, impactando fortemente a qualidade da água de forma a comprometer seus usos, sendo esse processo intensificado por ações antrópicas em águas interiores (Page, Kumar & Mishra, 2018). Os organismos autótrofos, por sua vez, utilizam a fotossíntese para produção de energia, e com isso emitem sinais de reflectância específicos pela clorofila que podem ser capturados por satélites.

Neste sentido, estratégias de monitoramento com maior eficiência, em grande escala e a baixo custo possuem papel fundamental para garantia da segurança sanitária dos reservatórios (Machado & Baptista, 2016).

Dentre as técnicas mais empregadas atualmente está o monitoramento *in situ* para variáveis biológicas como a clorofila-a (Chl-a), e parâmetros físicos (turbidez) por intermédio de estações de monitoramento automático, porém trata-se de um método caro e considerado a longo prazo de difícil aplicação, em decorrência das grandes

Universidad Nacional de Cuyo | Mendoza | Argentina
áreas ocupadas por reservatórios no Brasil (Novo & Tundisi, 1988, Boddula, Ramaswamy & Mishra, 2017).

Pensando nisso, métodos complementares ao monitoramento *in situ* vem sendo testados para uma melhor conservação dos recursos hídricos. Técnicas de sensoriamento remoto combinado com modelos estatísticos surgem como alternativa para estimar parâmetros individuais de qualidade da água (Wen, Zhou, Chen, Li, & Tang, 2014, Carswell, Costa, Young, Komick, Gower & Ruston, 2017, Toming, Hutser, Laas, Sepp, Paavel, & Nõges, 2016, Ogashawara, Alcantara, Curtarelli, Adami, Nascimento, Souza Stech, & Kampel, 2014, Page et al., 2018) como seu estado trófico (Machado & Baptista, 2016).

Dado a importância de inovação das técnicas de monitoramento da qualidade dos reservatórios e com avanço dos métodos de sensoriamento remoto,

17, 18 y 19 de octubre de 2018
neste trabalho mostraremos resultados e contribuições da aplicação dessa técnica, através da análise comparativa entre dados *in situ* e imagens de satélite MODIS para Represa Billings/SP.

Objetivos

Explicar a variação dos dados de clorofila-a e turbidez obtidos *in situ* utilizando imagens do satélite MODIS para um período de 15 anos.

Material e Métodos

Área de Estudo

Localizada no Estado de São Paulo (Brasil), a Represa Billings encontra-se ao sul da Região Metropolitana do estado (RMSP) e estende-se por seis municípios (São Paulo, Diadema, São Bernardo do Campo, Santo André, Ribeirão Pires e Rio Grande da Serra). Entre as coordenadas 23°47' S e 46°40' W (Figura 1), possui




Figura 1. Localização da Represa Billings no Estado de São Paulo, Brasil.

Universidad Nacional de Cuyo | Mendoza | Argentina
área aproximada de 120 km²,
profundidade média de 10 metros
(Companhia Ambiental do Estado de São
Paulo [CETESB], 2014), e, atualmente, é
considerado o maior reservatório de água
da RMSP.

Originada do barramento do Rio Grande em 1927, a finalidade inicial do represamento era a geração de energia com a usina hidrelétrica *Henry Borden* em Cubatão, no entanto com o aumento demográfico no entorno da represa e em toda a RMSP o reservatório desempenha hoje papel estratégico para o abastecimento público, atividades industriais, recreativas, lazer, náuticos e irrigação (CETESB, 2014).

Os diferentes usos atribuídos a água da represa Billings ocasionaram, no decorrer do tempo, mudanças em sua qualidade que despertaram a atenção de pesquisadores que desenvolvem estudos desde a década de 60 na represa (Branco, 1966). Entre as pesquisas realizadas no reservatório, muitas revelam a elevada diversidade de microrganismos que compõe o ecossistema aquático da área de estudo, entre elas espécies do fitoplâncton (Palmer, 1960, Xavier, 1979, Sant'Anna, 1984, Carvalho, 2003 Rodrigues, Sant'Anna & Tucci, 2010) que relacionam-se diretamente com a qualidade da água do reservatório, corroborando para o desenvolvimento de

17, 18 y 19 de octubre de 2018
estudos voltados ao monitoramento em
larga escala.

Dados de Clorofila-a e Turbidez

Por meio do Sistema de Informações *Online* (InfoÁGUAS) que fornece índices de qualidade da água superficial do estado de São Paulo, de responsabilidade da rede de monitoramento da Companhia Ambiental do Estado de São Paulo (CETESB), foram adquiridos dados referentes à concentração de Chl-a e turbidez no período de 2002 a 2017 amostrados na Represa Billings.

De acordo com protocolo da CETESB, o procedimento de coleta e análise das amostras de água são realizados seguindo as especificações: 1) as amostras de água são coletadas cerca de 30 cm abaixo da superfície (Agência Nacional de Águas [ANA], 2011); 2) a Chl-a é analisada por espectrofotometria monocromática (CETESB, 2014), baseada na absorvância em 3 diferentes comprimentos de onda (664, 665 e 750 nm) para estimar a clorofila-a e a informação é retornada em termos de pigmentos por unidades de volume (µg/L). Outro método utilizado pela CETESB é o monitoramento automático de variáveis como a turbidez, onde os dados são obtidos por estações fixas *in situ* com frequência horária e expresso em

Universidad Nacional de Cuyo | Mendoza | Argentina
Unidades Nefelométricas de Turbidez
(UNT).

Tendo em vista que os dados de qualidade da água são coletados em datas e pontos específicos, e que as imagens MODIS possuem limitações quanto a sua resolução espacial e temporal (conforme será discutido a seguir), apenas dois pontos de amostragem foram utilizados, cuja posição dentro da represa permite diminuir a mistura espectral com alvos do entorno: BILL02030, com 59 observações, e BILL02100, com 161 observações. Estes pontos se encontram no centro do corpo de água a aproximadamente 1 km da Represa da Pedreira e na altura do braço Taquacetuba, onde ocorre a transposição de água da represa Billings para a represa Guarapiranga.

Além disso, na perspectiva temporal, foram consideradas duas abordagens na comparação entre os dados de satélite e *in situ*: utilizando apenas datas coincidentes entre o(s) satélite(s) e as amostras, ou ainda um intervalo de um dia (antes e após a coleta das amostras) para as imagens MODIS em relação às amostras da CETESB. Maiores detalhes sobre as imagens são apresentados a seguir.

Dados MODIS

17, 18 y 19 de octubre de 2018
As imagens do satélite MODIS (*Moderate Resolution Imaging Spectroradiometer*) utilizadas referem-se ao produto MOD09GA, da plataforma Terra. Estas imagens apresentam um tempo de revisita de até 2 dias e resolução espacial de 500 metros, e são compostas por sete bandas na faixa espectral de 459 nm a 2155 nm, sendo os valores já submetidos ao processo de correção atmosférica e disponibilizados como valores de reflectância de superfície (Vermote e Wolfe, 2015). As imagens compreendem uma série temporal de 15 anos (2002-2017). Os dados foram carregados e processados diretamente na nuvem por meio da plataforma *Google Earth Engine* e sua linguagem de programação de aplicativos (API) específica (Gorelick, Hancher, Dixon, Ilyushchenko, Thau, & Moore, 2017).

Levando em consideração as limitações impostas pelo tamanho do pixel, foram selecionados apenas os pontos que localizam-se com todo pixel dentro do reservatório (Figura 2), a fim de evitar interferências de possível mistura espectral entre terra, usos do solo e a água, aplicando a máscara *Land Water Mask* (MOD44W.005) (Carroll, Townshend, DiMiceli, Noojipady, & Sohlberg, 2009). Além disso, dados de QA binários do próprio produto MOD09GA

Universidad Nacional de Cuyo | Mendoza | Argentina
foram usados para mascarar/ignorar
pixels de baixa qualidade e nublados.

17, 18 y 19 de octubre de 2018

Random Forest é um termo geral

que utiliza classificadores do tipo árvore. Constrói uma numerosa quantia de árvores de decisão a partir de um treinamento definido por um meta-algoritmo que melhora a classificação e a regressão de modelos de acordo com a estabilidade e precisão da classificação (Lopes, Goedtel, Palacios, & Godoy, 2017). É um método que pode ser aplicado quando há mais atributos que exemplos, onde haja problemas de duas classes ou multi-classes (Oshiro, 2013).

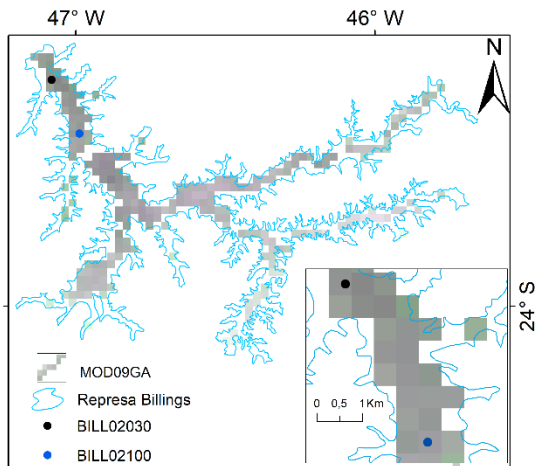


Figura 2. Imagem MODIS enfatizando a localização dos pixels na Represa Billings e os pontos de amostragem.

Para este trabalho foi utilizado para se obter maior significância nos resultados, visto que possui um bom desempenho de previsão embora a maioria das variáveis de previsão sejam ruídos, podendo lidar com uma combinação de atributos nominais e numéricos existindo menor necessidade de ajustar os parâmetros para atingir um desempenho bom (Oshiro, 2013). A partir de um conjunto de dados de treinamento originais, extrai casos aleatoriamente, utilizando os conjuntos para construir cada uma das árvores de decisão que compõem a *Random Florest*. Cada árvore classificadora é indicada como um item de previsão. A decisão é construída a partir da contagem dos votos dos itens de previsão em cada classe, e depois é selecionada a classe vencedora em

Modelo de Regressão *Stepwise*

Baseada na seleção de variáveis que exercem maior influência, ou seja, contribuição para o modelo, a regressão *Stepwise* consiste na inclusão (*forward*) e remoção (*backward*) das variáveis a fim de identificar a melhor combinação entre elas.

Neste trabalho adotamos o Critério de Informação de Akaike (AIC), onde foram realizadas regressões passo a passo com as setes bandas e o índice NDVI até obter o modelo com menor AIC. Posteriormente o desempenho da regressão *Stepwise* foi comparado com método não paramétrico *Random Forests*.

Algoritmo *Random Forest*

Universidad Nacional de Cuyo | Mendoza | Argentina
termos de números de votos acumulados
(Lopes et al., 2017).

17, 18 y 19 de octubre de 2018
importante apontar que ambos os
modelos apresentaram R^2 e AIC com
valores próximos.

Resultados e Discussão

Os valores coletados para as variáveis Chl-a e turbidez foram relacionados individualmente aos valores gerados a partir do teste de algoritmo das imagens MODIS, considerando apenas as datas coincidentes ou o período de um dia antes ou após a coleta das amostras, conforme já mencionado. A fim de descrever a relação entre os dados foi utilizado o método estatístico de regressão *Stepwise* e o algoritmo *Random Forest*.

Inicialmente, foi testado o modelo linear completo, composto pelas oito bandas do satélite MODIS, o qual apresentou uma explicação de 17% da variação da concentração de clorofila na represa Billings ($P < 0.001$). Posteriormente, foi utilizada a seleção de modelos de regressão *Stepwise* e o modelo que apresentou melhor explicação foi aquele composto pelas bandas 1, 2, 3, 5 e 7, com um $R^2 = 0.18$ ($P < 0.001$), caracterizando um modelo linear reduzido. Além disso, deve-se ressaltar que a melhor combinação das variáveis é identificada pelo modelo com o menor AIC e os valores deste critério para os modelos completo e reduzido foram 1681 e 1677, respectivamente. Entretanto, é

Já a técnica de inteligência artificial *Random Forest* indicou maior poder de explicação em relação aos modelos lineares, pois apresentou um pseudo- $R^2 = 0.32$. De acordo com este modelo algoritmo, as variáveis que mais contribuíram de maneira única para explicar a variação de clorofila foram as bandas 1, 2 e o índice NDVI, como pode ser observado na Figura 3.

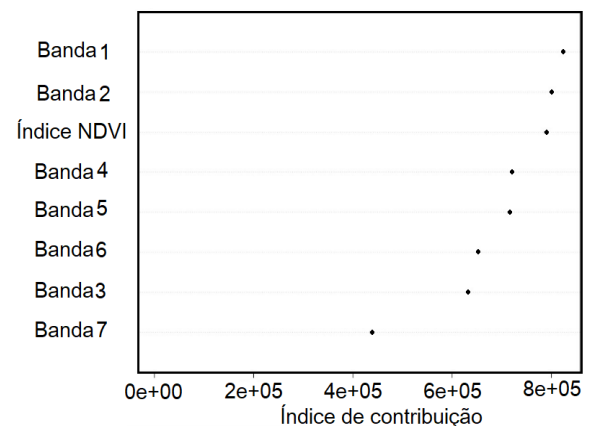


Figura 3. Contribuição das variáveis ao modelo *Random Forest*.

Em ambas as técnicas (*Stepwise* e *Random Forest*) houve destaque para as bandas 1 e 2, que demonstraram maior explicação da variação de clorofila-a conjuntamente com o Índice NDVI, por constituírem as bandas do vermelho, banda 1, e do infravermelho próximo, banda 2 (Latorre et al., 2003).

Com relação à turbidez, tanto os

Universidad Nacional de Cuyo | Mendoza | Argentina
modelos lineares como o *Random Forest* explicaram menos de 5% da variação dos dados, mostrando uma relação abaixo do esperando com as bandas de sensoriamento remoto.

A turbidez é considerada uma propriedade óptica do espalhamento de luz produzido pelas partículas sólidas encontradas no manancial (Pereira, 1992).

Está associada à erosão dos solos das margens, atividades de mineração, lançamento de esgotos, lançamento de efluentes industriais, dentre muitas outras atividades antrópicas responsáveis por trazer quantidades significativas de sólidos em suspensão (silte, argila, sílica, coloides), matéria orgânica e inorgânica, organismos microscópicos e algas (Pereira, 1992).

Desta maneira, as partículas em suspensão são responsáveis por alterar a turbidez da água, já que em grandes quantidades influenciam a transparência, modificando assim a radiação incidente e a radiação emergente da água, onde quanto maior a quantidade de partículas, maior será a reflectância do manancial (Ritchie, Schiebe & Mchenry, 1976, Pereira, 1992).

Com isso, o monitoramento por satélite pode ser considerado pouco eficiente para a variável, uma vez que a medida da transparência é o método mais prático e são necessários estudos mais

17, 18 y 19 de octubre de 2018
avanzados para trabalhar as diferentes reflectâncias.

A fim de verificar a qualidade de modelos mais complexos que resultassem em maior significância para explicar o método, as análises foram feitas unindo os dados MYD e MOD e dados de coleta *in situ* e imagem com *atraso* de um dia. A análise demonstrou resultados iguais aos anteriores, realizados apenas com dados MOD. Isto nos mostra que mesmo estratégias mais complexas não melhoraram a qualidade do modelo, reforçando a dificuldade de modelagem com esses dados.

Conclusão

Como visto neste trabalho, o avanço das técnicas de sensoriamento remoto (SR) pode reforçar o monitoramento da qualidade da água em reservatórios como a Represa Billings. Entre os modelos e variáveis testados o algoritmo *Random Forest* e a Chl-a apresentaram maior poder explicativo para a análise utilizando SR, sendo assim uma alternativa para atestar o uso desta técnica como possibilidade de monitoramento em larga escala e baixo custo operacional.

No Estado de São Paulo o monitoramento dos reservatórios é realizado, em média, de seis em seis meses. Entretanto, alguns reservatórios, a

Universidad Nacional de Cuyo | Mendoza | Argentina
partir de 2015, passaram a ser analisados mensalmente, em virtude do avanço das alterações da qualidade da água, como é o caso da Represa Billings.

O aumento da frequência de monitoramento *in situ* deste reservatório e de outros, reforça o uso de técnicas de SR para o monitorar a qualidade da água, que devem ser aperfeiçoadas e, posteriormente, incorporadas aos protocolos padrões de monitoramento.

Para alcançar resultados mais significativos, é recomendada a aplicação dos procedimentos adotados neste trabalho utilizando produtos de satélites com resolução espacial maior.

Bibliografia

Agência Nacional de Águas. (2011). *Guia Nacional de Coleta e Preservação de Amostras* (2ª Edição). Recuperado de <http://arquivos.ana.gov.br/institucional/sge/CEDOC/Catalogo/2012/GuiaNacionalDeColeta.pdf>

Carswell, T., Costa, M., Young, E., Komick, N., Gower, J., e Ruston, S. (2017). Evaluation of MODIS-Aqua Atmospheric Correction and Chlorophyll Products of Western North American Coastal Waters Based on 13 Years of Data. *Remote Sens.* 9(10), 1063-1064.

Boddula, V., Ramaswamy, L., e Mishra, D. (junho de 2017). A Spatio-Temporal Mining Approach for Enhancing Satellite

17, 18 y 19 de octubre de 2018

Data Availability: A Case Study on Blue Green Algae. En G. Karypis e J. Zhang (Presidencia), *IEEE 6th International Congress on Big Data*, Honolulu, Hawaii, USA.

Branco, S.M. (1966). Estudo das condições sanitárias da Represa Billings. *Arq. Fac. Hig. e Sau. Públ.*, 20(1), 57-86.

Carroll, M.L., Townshend, J.R., DiMiceli, C.M., Noojipady, P., e Sohlberg, R.A. (2009). A new global raster water mask at 250 m resolution. *International Journal of Digital Earth*, 2(4), 291-308.

Carvalho, M.C. (2003). *Comunidade fitoplanctônica como instrumento de biomonitoramento de reservatórios no Estado de São Paulo* (Tese de doutorado). Universidade de São Paulo, São Paulo, Brasil.

Companhia Ambiental do Estado de São Paulo. (2014). *Sistema de informação InfoÁGUAS*. São Paulo, BR.: Relatórios. Recuperado de <https://servicos.cetesb.sp.gov.br/infoaguas/>

Norma Técnica. Companhia Ambiental do Estado de São Paulo. (fevereiro de 2014). *Determinação de Clorofila a e Feofitina a: método espectrofotométrico*. Recuperado de <http://sistemasinter.cetesb.sp.gov.br/normas/11/2013/11/L5306.pdf>

Elliott, J. A., Jones, I. D., e Thackeray, S. J. (2006). Testing the Sensitivity of

Universidad Nacional de Cuyo | Mendoza | Argentina

Phytoplankton Communities to Changes in Water Temperature and Nutrient Load, in a Temperate Lake. *Hydrobiologia*, 559(1), 401–411.

Gemelgo, M.C.P., Sant'Anna, C.L., Tucci, A., e Barbosa, H.R. (2008). Population dynamics of *Cylindrospermopsis raciborskii* (Woloszynska) Seenayya & Subba Raju, a Cyanobacteria toxic species, in water supply reservoirs in São Paulo, Brazil. *Hoehnea*, 35(2), 297-307.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko., Thau, D., e Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of environment*, 202(1), 18–27.

Latorre, M., Anderson, L.O., Shimabukuro, Y.E, e Carvalho Júnior, O.A. (2003). Sensor MODIS: Características gerais e aplicações. *Revista Espaço & Geografia*, 6(1), 91-121.

Lopes, T.D., Goedel, A., Palacios, R.H.C., e Godoy, W.F. (outubro de 2017). Aplicação do algoritmo Random Forest como classificador de padrões de falhas em rolamentos de motores de indução. En João Manoel e Carlos Pereira (Presidência), *Xiii Simpósio Brasileiro de Automação Inteligente*, Porto Alegre, Rio Grande do Sul, Brasil.

Machado, M.T.S., e Baptista, G.M.M. (2016). Sensoriamento remoto como ferramenta de monitoramento da

17, 18 y 19 de octubre de 2018

qualidade da água do Lago Paranoá (DF). *Eng. Sanit. Ambient.*, 21(2), 357-365.

Novo, E.M.L.M., Tundisi, J.G. (outubro de 1988). Sensoriamento remoto de águas interiores: perspectivas. *Simpósio Brasileiro de Sensoriamento Remoto*, São José dos Campos, São Paulo, Brasil.

Ogashawara, I., Alcantara, E.H., Curtarelli, M.P., Adami, M., Nascimento, R.F.F., Souza, A.F., Stech, J.L., e Kampel, M. (2014). Performance Analysis of MODIS 500-m Spatial Resolution Products for Estimating Chlorophyll-a Concentrations in Oligo- to Meso-Trophic Waters Case Study: Itumbiara Reservoir, Brazil. *Remote Sens.* 5(2), 1634-1653.

Oshiro, T. M. (2013). *Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica* (Dissertação de mestrado). Universidade de São Paulo, Ribeirão Preto, Brasil.

Page, B.P, Kumar, A., e Mishra, D.R. (2018). A novel cross-satellite based assessment of the spatio-temporal development of a cyanobacterial harmful algal bloom. *Int J Appl Earth Obs Geoinformation*, 66, 69-81.

Palmer, C.M. (1960) Algas e suprimento de água na área de São Paulo. *Revista do Departamento de Água e Esgoto*, 21(37), 11-15.

Universidad Nacional de Cuyo | Mendoza | Argentina

Pereira, M.D. B., e Santos, E. (1992). Parâmetros limnológicos passíveis de serem monitorados através de dados espectrais obtidos por sensores remotos orbitais (Tese de doutorado) Universidade de São Paulo, São Carlos, Brasil.

Ritchie, J. C., Schiebe, F. R., e Mchenry, J. R. (1976). Remote Sensing of Suspended Sediments in Surface Water. *Photogrammetric Engineering and Remote Sensing*. 42(12), 1539-1545.

Rodrigues, L.L., Sant'Anna, C.L., e Tucci, A. (2010). Chlorophyceae das represas Billings (Braço Taquacetuba) e Guarapiranga, SP, Brasil. *Revista Brasil. Bot.*, 33(2), 247-264.

Sant'Anna, C.L. (1984). Chlorococcales (Chlorophyceae) do Estado de São Paulo, Brasil (Tese de doutorado) Universidade do Texas, Texas, EUA.

Silva, A.P.S., Dias, H.C.T., Bastos, R.K.X., e Silva, E. (2009). Qualidade da água do reservatório da usina hidrelétrica (UHE) de Peti, Minas Gerais. *Revista Árvore*, 33(6), 1063-1069.

Souza, W.F.L., Medeiros, P.R.P., Brandini, N., e Knoppers, B. (2011). Impactos de Barragens sobre os Fluxo de Materiais na Interface Continente-Oceano. *Revista Virtual de Química*, 3(2), 116-128.

Toming, K., Hutser, T., Laas, A., Sepp, M., Paavel, B., e Nõges, T. (2016). First Experiences in Mapping Lake Water

17, 18 y 19 de octubre de 2018

Quality Parameters with Sentinel-2 MSI Imagery. *Remote Sens.*, 8(8), 640.

Tundisi, J.G. (2001) *Planejamento e Gerenciamento de Lagos e Reservatórios: uma abordagem integrada ao problema da eutrofização*. São Carlos, Brasil: Rima.

Vermote, E., Wolfe, R. (2015). MOD09GA MODIS/Terra Surface Reflectance Daily L2G Global 1km and 500m SIN Grid V006 [Dataset]. Recuperado de https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table/mod09ga_v006

Wen, X., Zhou, Z., Chen, B., Li, Z., e Tang, X. (março de 2014). Research on the Features of Chlorophyll-a Derived from RapidEye and EOS/MODIS Data in Chaohu Lake. 35th International Symposium on Remote Sensing of Environment (ISRS35): Earth Observation and Global Environmental Change - 50 Years of Remote Sensing: Progress and Prospects. Beijing, China.

Xavier, M.B. (1979). *Contribuição ao estudo da variação sazonal do fitoplâncton na Represa Billings, São Paulo* (Dissertação de Mestrado). Universidade de São Paulo, São Paulo, Brasil.

Agradecimentos

Os produtos MOD09GA e MOD44W.005 foram acessados através da plataforma *Google Earth Engine* (GEE), em uma parceria entre as

Universidad Nacional de Cuyo | Mendoza | Argentina
instituições responsáveis pelos dados
(*University of Maryland* e NASA) e a
Google Inc.

17, 18 y 19 de octubre de 2018

Nossos agradecimentos à
Companhia Ambiental do Estado de São
Paulo (CETESB) pela disponibilização dos
dados de qualidade da água.

Agradecemos também aos
desenvolvedores que compartilharam os
códigos que foram adaptados aos
objetivos do presente trabalho na
plataforma GEE.