








Uso de Sensoriamento Remoto e Quimiometria como Ferramentas para Estimar Parâmetros de Qualidade da Água em Lagos Intermitentes do Baixo Rio Doce

Use of Remote Sensing and Chemometrics as Tools to Estimate Parameters of Water Quality in Intermittent Lakes of the Lower Doce River

Luis Guilherme Rodrigues Miranda,^a  Karla Pereira Rainha,^{a,*}  Pedro Henrique Pereira da Cunha,^a  Hudson Costa Oliveira,^b  Gilberto Fonseca Barroso,^c  Paulo Roberto Filgueiras,^a  Eustáquio Vinicius Ribeiro de Castro^a 

^a Universidade Federal do Espírito Santo), Centro de Ciências Exatas, Núcleo de Competências em Química do Petróleo (NCQP/Labpetro), Campus de Goiabeiras, CEP 29075-910, Vitória-ES, Brasil.

^b Universidade Federal do Rio de Janeiro, Departamento de Geologia, Instituto de Geociências, Cidade Universitária, CEP 21941-916, Rio de Janeiro-RJ, Brasil.

^c Universidade Federal do Espírito Santo, Centro de Ciências Humanas e Naturais, Departamento de Oceanografia e Ecologia, Campus de Goiabeiras, CEP 29075-910, Vitória-ES, Brasil.

*E-mail: professora.rainha@gmail.com

Recebido em: 22 de Agosto de 2022

Aceito em: 15 de Fevereiro de 2023

Publicado online: 5 de Abril de 2023

In this work, chemometric prediction models were developed using remote sensing images associated with limnological parameters to evaluate the water quality of intermittent lakes of the Baixo Rio Doce (Southeast - Brazil). The lakes, popularly known as Lagoa Juparanã and Lagoa Nova, are located in areas that were affected by the environmental disaster of the Fundão iron ore tailings dam (Minas Gerais). The visible and near infrared reflectance bands were extracted from images of the lakes surface, which were recorded by the Landsat-8 satellite on the dates closest to the days of field collection. After atmospheric correction of the spectral data, the models were built using Regression by Support Vectors to estimate the water quality parameters, which presented results satisfactory by the correlation coefficient of the prediction (R^2_{pred}) and by the square root of the mean squared prediction error (RMSEP), respectively: total phosphorus (0.817; 7.305 $\mu\text{g L}^{-1}$), turbidity (0.984; 1.467 UNT), transparency (0.705; 0.785 m), chlorophyll-a (0.850; 0.457 $\mu\text{g L}^{-1}$) and developed average trophic state index based on the Carlson equation (0.712; 2.617). This technique enables remote analysis of limnological parameters, which can help in environmental monitoring and equipping managers for more efficient decision-making in water resources conservation actions.

Keywords: Remote sensing; multivariate calibration; water quality; lakes.

1. Introdução

O uso consciente dos recursos hídricos associado ao monitoramento de qualidade da água são condicionantes essenciais para viabilizar o desenvolvimento sustentável de uma determinada região.^{1,2} O nível de conservação dos corpos hídricos está estritamente relacionado ao estágio de eutrofização, processo natural promovido pelo aumento de nutrientes nos ambientes aquáticos, em especial o fósforo e o nitrogênio. A intervenção humana intensifica a extensão e os efeitos da eutrofização, devido ao despejo de efluentes domésticos, industriais e agropastoris, aumentando a concentração de nutrientes orgânicos e inorgânicos, proporcionando as condições que favorecem o crescimento exagerado dos organismos autotróficos como, por exemplo, as microalgas planctônicas e macrófitas aquáticas.³⁻⁵

Os lagos Juparanã e Nova são localizados no município de Linhares, no estado do Espírito Santo (Sudeste - Brasil), em uma região caracterizada por apresentar temperatura média de 23,4 °C, precipitação pluviométrica com média anual de 1193 mm e ventos predominantemente de nordeste e sudeste, e classificada como de clima tropical quente e úmido, com altos índices de chuvas no verão e inverno seco.⁶ Na Figura 1 está a representação do mapa com a localização dos lagos Juparanã e Nova, que integram o sistema lacustre do Baixo Rio Doce.

Estes lagos, popularmente conhecidos como Lagoa Juparanã e Lagoa Nova, estão geologicamente embasados sobre rochas pré-cambrianas recobertas por sedimentos terciários da Formação Barreiras, depositadas durante o Pleistoceno e sobre planícies deltaicas quaternárias.^{7,8} O sistema lacustre do Baixo Rio Doce é diversificado quanto à gênese, morfometria, influência fluvial e marinha, além do estado trófico e fisiografia da classificação do grau de eutrofização, bacia de drenagem.⁹

De acordo com Bozelli *et al.* (1992),¹⁰ lagos são ecossistemas de funcionamento profundos com estratificação da coluna d'água e fundo afótico, ou seja, região que não recebe a incidência de

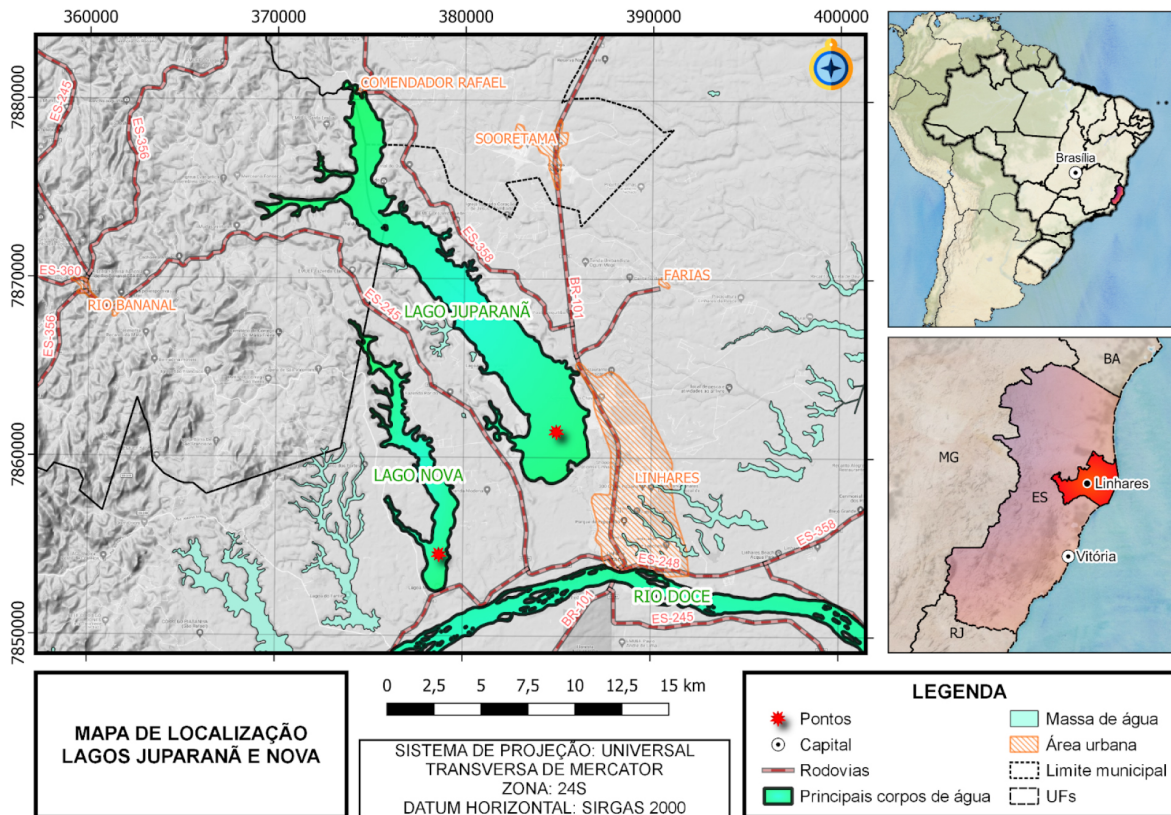


Figura 1. Localização dos Lagos Juparanã e Nova na região do Baixo Rio Doce em Linhares (Espírito Santo - Brasil)

luz solar.⁸⁻¹¹ E conforme Barroso, Gonçalves e Garcia (2014), Juparanã e Nova são lagos intermitentes com estratificação térmica na primavera e verão, e de mistura no outono e inverno, sendo encaixados nos vales de Formação Barreiras, com elevadas profundidades de até 50 m, e caracterizados pelo formato alongado, típico de vales afogados por represamento natural dos tributários do rio Doce.^{8,9} Portanto, Juparanã e Nova são definidos como lagos tropicais profundos, de acordo com a morfometria promovem águas longas e induz padrão de mistura monomítica quente.⁸⁻¹¹

Os lagos Juparanã e Nova fazem parte do Programa de Monitoramento da Biodiversidade Aquática (PMBA), dedicado ao dimensionamento dos impactos ambientais do rompimento da barragem de rejeitos de minério de ferro de Fundão em Mariana (Minas Gerais - Brasil), ocorrido no dia 05 de novembro de 2015. O PMBA é executado pela Rede Rio Doce Mar (RRDM) e pela Fundação Espírito-Santense de Tecnologia (FEST) em cooperação com a Fundação Renova, cujas ações são acompanhadas pela Câmara Técnica de Conservação e Biodiversidade (CTBio), sob coordenação do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio). Neste desastre ambiental, uma quantidade significativa de material particulado foi despejada no rio Doce e carreado até a região marinha adjacente, prejudicando a qualidade das águas, o ecossistema e sua biodiversidade.¹²

Os fenômenos desencadeados pela contaminação da lama de rejeitos ainda não são totalmente compreendidos,

mas possivelmente afetam o processo de eutrofização que modifica as propriedades óticas dos corpos d'água, como as alterações de coloração, que são expressos pelas respostas espectrais. Os sólidos em suspensão que se espalham nas águas dos lagos Juparanã e Nova, promoveram o aumento na turbidez, reduzindo a luminosidade e o oxigênio disponível, e consequentemente prejudicando a vida aquática.¹³ A reflectância da superfície de um corpo d'água é captada por sensores de satélites orbitais, e essas informações podem ser aplicadas no sensoriamento remoto. No entanto, esses conjuntos de dados estão restritos à camada superficial da água devido à forte atenuação da radiação eletromagnética.¹⁴ A água pura, possui reflectância próxima de zero, logo, a cor e a intensidade da luz refletida estão altamente correlacionadas com os dissolvidos e em suspensão.¹⁵

As faixas do espectro eletromagnético mais interessantes para a avaliação de qualidade da água estão compreendidas entre a região do visível (400 a 700 nm) até o infravermelho próximo (850 a 880 nm), pois é neste intervalo de maximização dos sinais característicos da substância água.¹⁶

Para mensurar a transparência da coluna d'água de um corpo hídrico, que é um fenômeno de não reflexão da luz, os principais modelos encontrados na literatura frequentemente relacionam os baixos valores de reflectância nas bandas do visível com os valores medidos em *in situ* pela determinação da profundidade do disco de Secchi.¹⁷⁻¹⁹

A clorofila-a é um indicador chave de biomassa fitoplanctônica e apresenta como característica espectral os

picos de reflectância no verde (aproximadamente 550 nm) e no infravermelho próximo (aproximadamente 850 nm), o que fazem dessas bandas, as variáveis descritoras deste parâmetro.²⁰

Para turbidez, geralmente utiliza-se os comprimentos de ondas referentes a banda do vermelho (aproximadamente 650 nm) e do infravermelho próximo, independentemente ou combinadas entre si.^{21,22} Nos modelos de múltiplas bandas espectrais, nota-se também a utilização dos sinais nos comprimentos de ondas na região do verde.¹⁸

As concentrações de fósforo e nitrogênio são opticamente inativas nestas faixas espectrais, no entanto como são os principais nutrientes para o encadeamento do processo de eutrofização, podem ser mensuradas de forma indireta com auxílio de ferramentas matemáticas e estatísticas.⁴

A calibração multivariada é uma técnica quimiométrica que associa as medidas instrumentais, como dados espectroscópicos, aos resultados experimentais dos parâmetros de referência.²³⁻²⁷ O *Support Vector Machines* é um método de aprendizagem de máquinas desenvolvido por Drucker *et al.* (1997), que foi primeiramente elaborado para a classificação de amostras, e depois a Regressão por Vetores de Suporte (SVR - *Support Vector Regression*) foi desenvolvida com a finalidade de ser aplicada na resolução de problemas de interesse químico não lineares.²⁶⁻²⁸ A calibração usando SVR é atualmente reconhecida pela sua aplicabilidade aos problemas lineares e não lineares e para que isso ocorra é necessário a utilização de uma função *kernel*, que pode ser linear, sigmóide e radial.²⁷

Este trabalho tem por objetivo desenvolver modelos quimiométricos para estimar alguns parâmetros de qualidade da água em lagos intermitentes com uso de sensoriamento remoto, associando os dados espectrais do satélite Landsat-8 e os resultados das propriedades limnológicas (fósforo total, turbidez, transparência e clorofila-a) e do índice de estado trófico para os lagos Juparanã e Nova, do Baixo Rio Doce.

2. Materiais e Métodos

2.1. Amostragem em campo e análises laboratoriais

A amostragem ocorreu mensalmente nas estações amostrais dos Lagos Juparanã e Nova (Figura 1), no período entre 21 de março de 2019 até 17 de setembro de 2021. Antes do início das coletas, as estações amostrais localizadas nestas duas dulcícolas foram georreferenciadas. Em cada ponto de coleta em campo, foram registradas as coordenadas geográficas por GPS do posicionamento da embarcação em relação às estações amostrais. Durante as amostragens, foi mensurada a Transparência (SDD) do lago com disco de Secchi dado em metros (m) e a Turbidez (Turb) com uso de sondas multiparâmetros YSI Horiba U-53 e Exo2, previamente calibradas, em Unidade Nefelométrica de Turbidez (UNT). Foram selecionadas 12 campanhas para compor o conjunto amostral deste trabalho. As amostras

de água dos lagos foram coletadas com garrafa de Niskin, acondicionadas em frascos de polipropileno (1 L), mantidos refrigerados e ao abrigo da luz para transporte ao laboratório. Para determinação de fósforo total (TP), as alíquotas foram digeridas com solução de persulfato de potássio e reduzidas a fosfato e, posteriormente, foram quantificadas no espectrofotômetro ($\mu\text{g L}^{-1}$).²⁹ A concentração de clorofila-a (Chla) foi determinada por fluorimetria ($\mu\text{g L}^{-1}$), após a extração com acetona 90 % e acidificação para conversão de feopigmentos.³⁰

Para o cálculo do Índice de Estado Trófico (IET), adotou-se o modelo de Carlson (1977), usualmente aplicado na avaliação do estado trófico de sistemas lacustres, considerando os parâmetros de qualidade: fósforo total (equação 1), transparência da coluna d'água (equação 2) e clorofila-a (equação 3) e o índice médio (equação 4). As classes de estado trófico segundo a variação do índice integrado ou médio são apresentadas na Tabela 1.³¹

$$IET(TP) = 10 \cdot \left\{ 6 - \left[\frac{\ln 48 / TP}{\ln 2} \right] \right\} \quad (1)$$

$$IET(SDD) = 10 \cdot \left\{ 6 - \left[\frac{\ln(SDD)}{\ln 2} \right] \right\} \quad (2)$$

$$IET(Chla) = 10 \cdot \left\{ 6 - \left[\frac{2,04 - 0,68 \ln(Chla)}{\ln 2} \right] \right\} \quad (3)$$

$$IET(\text{Médio}) = \frac{IET(SDD) + IET(Chla) + IET(TP)}{3} \quad (4)$$

onde: IET(TP) = Índice de Estado Trófico para Fósforo Total; IET(SDD) = Índice de Estado Trófico para Transparência; IET(Chla) = Índice de Estado Trófico para Clorofila-a e IET(Médio) = Índice de Estado Trófico Médio.

Tabela 1. Categorias de estado trófico dadas pelo modelo de Carlson³¹

Categorias de Estado Trófico para corpos d'água	Faixas do Índice de Estado Trófico (IET)
Ultraoligotrófico	IET ≤ 20
Oligotrófico	21 < IET ≤ 40
Mesotrófico	41 < IET ≤ 50
Eutrófico	51 < IET ≤ 60
Hipereutrófico	IET > 61

2.2. Métodos de seleção e processamento das imagens

As cenas do satélite Landsat-8 OLI (*Operational Land Imager*) foram obtidas gratuitamente no banco de dados disponibilizado pelo Serviço Geológico dos

Estados Unidos (USGS - *United States Geological Survey*), acessado pelo portal *EarthExplorer* (<https://earthexplorer.usgs.gov/>), utilizando como critério de busca a órbita: 215 fileira: 073.³² Foram escolhidas as imagens da superfície da água destes lagos registradas nas datas coincidentes ou mais próximas aos dias de coleta em campo, considerando a resolução temporal de 16 dias do satélite Landsat-8. A ausência de cobertura de nuvens sobre os lagos também foi usada como critério de seleção, após a obtenção das cenas, as imagens foram submetidas aos seguintes processamentos: correção geométrica, correção atmosférica e conversão de números digitais (ND) em reflectância.

A correção geométrica ou georreferenciamento promove o referenciamento das imagens a um mapa com a finalidade de reduzir as distorções causadas, principalmente, pela rotação e curvatura do globo terrestre, variação da altitude entre outros fatores geométricos. O sistema de coordenadas utilizado foi o UTM (*Universal Transversa de Mercator*).¹⁵

A correção atmosférica foi aplicada para reduzir os efeitos aditivos e subtrativos dos constituintes da atmosfera, com intuito de conferir à imagem apenas a informação espectral do alvo, sem influência, por exemplo, de nuvens, moléculas de gás e aerossóis.³³

O método de correção utilizado neste trabalho foi o algoritmo LaSRC (*Land Surface Reflectance Code*), modelo físico que calcula a reflectância de superfície e temperatura de brilho a partir dos parâmetros de calibração contidos nos metadados da imagem. A correção atmosférica foi aplicada a partir de parâmetros como concentração de vapor d'água, ozônio, espessura óptica de aerossol, obtidos de forma indireta. O algoritmo também utiliza o modelo digital de elevação GTOPO no cálculo da pressão atmosférica, utilizada para definição de concentrações de aerossóis e detecção de nuvens de cirros.³⁴

Após o processo de correção atmosférica, a média dos números digitais (ND) dos *pixels* referentes a cada ponto de amostragem e dos 9 vizinhos mais próximos, foram convertidos para dados de reflectância espectral de topo. Nesta etapa, foram consideradas as variações da distância Sol-Terra, ângulo zênite solar, e dados de ganho e *offset*, informações estas, também contidas no metadado das imagens.³⁵ Todos os procedimentos de correção das cenas foram realizados no *software* QGIS (versão 3.16.8).

O conjunto de datas correspondentes as 12 campanhas em campo e os respectivos dias de aquisição de cada imagem orbital estão relacionadas na Tabela 2.

Tabela 2. Data das campanhas em campo e das imagens utilizadas na construção e validação dos modelos

Dia da amostragem da água in situ	Dia de aquisição pelo satélite Landsat-8 OLI
21/03/2019	14/03/2019
13/06/2019	02/06/2019
18/07/2019	20/07/2019
19/09/2019	22/09/2019
12/12/2019	11/12/2019
14/01/2020	12/01/2020
17/12/2020	13/12/2020
11/02/2021	15/02/2021
11/05/2021	22/05/2021
15/06/2021	07/06/2021
13/07/2021	09/07/2021
17/09/2021	10/09/2021

2.3. Modelos de regressão multivariada

Foram selecionadas as bandas 2 (B2, correspondente ao azul), 3 (B3, referente à região do verde), 4 (B4, à luz vermelha) e 5 (B5, ao infravermelho próximo), devido ao comportamento espectral da água. Em ausência de sólidos em suspensão, a água apresenta o seu pico de reflectância na faixa do azul até o verde (B2 e B3) apresenta tendência de ocorrer o deslocamento do sinal para as regiões com o maior comprimento de onda, na faixa do vermelho até o infravermelho próximo (B4 e B5), devido à incorporação de sólidos em suspensão. As variáveis de entrada dos modelos foram descritas na Tabela 3.

No caso dos modelos de SVR, foram otimizados os parâmetros custo (C), margem (ϵ) e gamma (γ), além de ajuste da função *kernel*, que variaram entre as faixas 0,0001-10.000, 0,0001-1 e 0,0001-10, respectivamente. O *kernel*, de função de base radial e grade de pesquisa de 32 pontos, foi utilizado no processo de otimização, com os melhores parâmetros definidos pelo menor RMSECV (*Root Mean Square Error of Cross Validation*). Foram determinadas as figuras de mérito para o modelo selecionado.²⁶

Os modelos foram desenvolvidos utilizando o *software Matlab* (versão 2016a). Os dados de entrada foram autoescalados, centrados na média e normalizados na etapa de pré-processamento e, em seguida, divididos em dois conjuntos: o primeiro com 70 % das amostras, denominado conjunto de calibração, e o segundo com 30 %, o conjunto de teste.

Tabela 3. Bandas espectrais utilizadas na construção dos modelos de regressão multivariada³²

Nome das Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)
Azul (B2)	0,45-0,51	30
Verde (B3)	0,53-0,59	30
Vermelho (B4)	0,64-0,67	30
Infravermelho próximo (B5)	0,85-0,88	30

2.4. Métricas de avaliação dos modelos de regressão

Na etapa da avaliação da eficiência dos modelos de regressão foram utilizados os seguintes procedimentos: Identificação de amostras anômalas, observando o número de *leverages*; Análise do coeficiente de correlação (R^2) (equação 5); Comparação entre os valores medidos (resposta da calibração) e previstos; Verificação dos erros através da raiz quadrada do erro quadrático médio de calibração (RMSEC - *Root Mean Square Error of Calibration*), de calibração cruzada (RMSECV - *Root Mean Square Error of Cross Validation*) e de predição (RMSEP - *Root Mean Square Error of Prediction*), representadas nas equações 6, 7 e 8, respectivamente.^{23,25}

$$R^2 = 1 - \frac{\sum_i (y_i - \bar{y}_i)^2}{\sum_i (y_i - \hat{y}_i)^2} \quad (5)$$

$$\text{RMSECV} = \sqrt{\frac{\sum_{i=1}^{n_{\text{cal}}} (y_i - \hat{y}_i)^2}{n_{\text{cal}} - 1}} \quad (6)$$

$$\text{RMSEC} = \sqrt{\frac{\sum_{i=1}^{n_{\text{pred}}} (y_i - \hat{y}_i)^2}{n_{\text{cal}}}} \quad (7)$$

$$\text{RMSEP} = \sqrt{\frac{\sum_{i=1}^{n_{\text{pred}}} (y_i - \hat{y}_i)^2}{n_{\text{pred}}}} \quad (8)$$

onde: y_i = valor previsto pelo modelo; \bar{y}_i = valor médio de referência; \hat{y}_i = valor de referência; n_{cal} = total de amostras do conjunto de calibração; n_{pred} = total de amostras do conjunto de predição.

3. Resultados e Discussão

3.1. Análise dos parâmetros de qualidade da água

Os resultados das propriedades limnológicas, ou seja, dos parâmetros de qualidade da água obtidos para as amostras coletadas nos lagos apresentaram as seguintes faixas de abrangência: fósforo total 21,21-400,04 ($\mu\text{g L}^{-1}$); turbidez 0-20,8 UNT; transparência 0,8-6,2 m; clorofila-a 0,46-5,65 ($\mu\text{g L}^{-1}$); IET(TP) 48,21-90,59; IET(SDD) 33,67-63,21; IET(Chla) 22,89-47,55 e IET(Médio) 36,57-67,12. Analisando a Tabela 4, onde são expressos os resultados estatísticos, é importante destacar o baixo valor de desvio padrão da clorofila-a e transparência, e também se evidencia que a turbidez e a concentração de fósforo total apresentaram desvios maiores do que os valores médios, o que indica uma alta dispersão dos dados e heterogeneidade das amostras, o que não é o ideal.

3.2. Avaliação da correlação de Pearson

A correlação de Pearson foi utilizada para avaliar as relações entre as variáveis de entrada no modelo, em que as informações espectrais (reflectâncias das bandas) correspondem a matriz X e os resultados dos parâmetros de qualidade da água (propriedades limnológicas) são os elementos constituintes da matriz Y, conforme equação 9. As respostas obtidas estavam compreendidas entre -1 e 1, assim as correlações mais fortes são descritas pelos maiores valores absolutos (Tabela 5).

$$r = \frac{\sum XY - \frac{\sum X \sum Y}{N}}{\sqrt{\left(\sum X^2 - \frac{(\sum X)^2}{N}\right)\left(\sum Y^2 - \frac{(\sum Y)^2}{N}\right)}} \quad (9)$$

Foi observado que o conjunto dos resultados para o teor de fósforo total apresentou correlação negativa com as intensidades das bandas analisadas na região do visível (B2, B3 e B4) e do infravermelho próximo (B5). Como mencionado anteriormente, a concentração TP é uma propriedade opticamente inativa, ou seja, não possui correlação com a resposta espectral na faixa do visível. Quanto maior o sinal das bandas espectrais (B2, B3 e B4) menor será a quantidade de fósforo, entendendo que nesta condição, este nutriente está sendo consumido, resultando na produção de outros compostos que são opticamente ativos, como a clorofila-a e matéria orgânica, que se desenvolvem a partir deste consumo.

A análise de Pearson para turbidez demonstrou a ocorrência de correlações altas (acima de 0,5), dos sinais das bandas de reflectância da região do verde (B3; 0,765) e vermelho (B4; 0,545).

O resultado para o parâmetro transparência indica que quanto maior a transparência, menor será o sinal de reflectância, o que era esperado, pois a transparência é o fenômeno de não reflexão da luz.

O parâmetro clorofila-a (Chla) não apresentou correlações significativas com todas as bandas espectrais analisadas (B2, B3, B4 e B5). Entretanto, é possível observar o deslocamento de sinal provocado pelo aumento da concentração de clorofila-a, pois estabelece relação inversa com os sinais do azul (B2) e do infravermelho próximo (B5), e diretamente proporcional com a banda do verde (B3).

3.3. Avaliação do desempenho preditivo dos modelos

Os resultados de calibração e predição foram avaliados com base nas respostas espectrais apresentadas. Foram considerados como fatores descritores de eficiência dos modelos, principalmente, os menores valores registrados para os erros de predição e de calibração, além dos maiores coeficientes de regressão. Os dados utilizados na etapa de avaliação do desempenho dos modelos desenvolvidos para

Tabela 4. Estatística descritiva com os dados das propriedades limnológicas e dos índices de estado trófico

Propriedades Limnológicas ^a	Mínimo	Máximo	Média	Desvio Padrão
TP ($\mu\text{g L}^{-1}$)	21,21	400,04	59,84	82,90
Turb (UNT)	0	20,80	5,38	6,63
SDD (m)	0,80	6,20	2,94	1,66
Chla ($\mu\text{g L}^{-1}$)	0,46	5,65	2,03	1,44
IET(TP)	48,21	90,59	57,90	10,08
IET(SDD)	33,67	63,21	47,17	9,66
IET(Chla)	22,89	47,55	35,17	7,03
IET(Médio)	36,57	67,12	46,75	7,68

^a Abreviaturas das propriedades limnológicas: TP = Fósforo Total; Turb = Turbidez; SDD = Transparência; Chla = Clorofila-a; IET(TP) = Índice de Estado Trófico para Fósforo Total; IET(SDD) = Índice de Estado Trófico para Transparência; IET(Chla) = Índice de Estado Trófico para Clorofila-a; IET(Médio) = Índice de Estado Trófico Médio.

Tabela 5. Resultados da correlação de Pearson entre as variáveis limnológicas e espectrais

Propriedades Limnológicas	Banda do Azul (B2)	Banda do Verde (B3)	Banda do Vermelho (B4)	Banda do Infravermelho próximo (B5)
TP ($\mu\text{g L}^{-1}$)	-0,796	-0,035	-0,311	-0,380
Turb (UNT)	0,149	0,765	0,545	-0,259
SDD (m)	-0,148	-0,650	-0,433	0,187
Chla ($\mu\text{g L}^{-1}$)	-0,264	0,286	0,089	-0,287

Legenda: TP = Fósforo Total; Turb = Turbidez; SDD = Transparência; Chla = Clorofila-a.

as propriedades limnológicas investigadas e IET(Médio) conforme Carlson,³¹ são apresentados na Tabela 6.

O modelo SVR para a determinação de Fósforo Total (TP) apresentou coeficientes de regressão acima de 0,8 (R^2_{cal} 0,992; R^2_{cv} 0,978; R^2_{pred} 0,817), RMSEC 8,415 ($\mu\text{g L}^{-1}$), RMSECV 13,967 ($\mu\text{g L}^{-1}$) e RMSEP 7,305 ($\mu\text{g L}^{-1}$), esta calibração destacou-se pela precisão significativa (Figura 2). Os resíduos do modelo SVR selecionado demonstraram distribuição uniforme, pois o teste tendência aplicado não apontou a ocorrência de erros sistemáticos significativos.

Hossen *et al.* (2022) desenvolveram um modelo quadrático com os dados do satélite Sentinel-2 para estimar TP, com uso da razão entre os sinais da banda do infravermelho próximo (NIR) (B8) com a banda do verde (B3), ou seja, razão B8/B3.⁴ Os autores consideraram o modelo com R^2 0,733 e erro quadrado médio normalizado (NRMSE - *Normalized Root Mean Square Error*) de 0,16 ($\mu\text{g L}^{-1}$), construído com ampla faixa de trabalho, com variação de 177,14 a 988,64 ($\mu\text{g L}^{-1}$), como o melhor resultado de predição.⁴ Como os autores apresentaram o

Tabela 6. Resultados dos modelos de calibração multivariada por SVR para Fósforo Total, Turbidez, Transparência, Clorofila-a e IET(Médio)

Modelo SVR	TP ($\mu\text{g L}^{-1}$)	Turb (UNT)	SDD (m)	Chla ($\mu\text{g L}^{-1}$)	IET(Médio)
R^2_{cal}	0,992	0,962	0,584	0,350	0,747
R^2_{cv}	0,978	0,887	0,419	0,293	0,727
R^2_{pred}	0,817	0,984	0,705	0,850	0,712
RMSEC	8,415	1,219	1,059	1,264	4,045
RMSECV	13,967	2,184	1,258	1,305	4,242
RMSEP	7,305	1,467	0,785	0,457	2,617
Bias Calibração	1,446	0,518	0,090	0,133	0,206
Bias Predição	5,697	0,737	0,240	-0,365	-0,747

Legenda: SVR = Regressão por Vetores de Suporte (*Support Vector Regression*); TP = Fósforo Total; Turb = Turbidez; SDD = Transparência; Chla = Clorofila-a; IET(Médio) = Índice de Estado Trófico Médio; R^2_{cal} = coeficiente de correlação da calibração; R^2_{cv} = coeficiente de correlação da calibração cruzada; R^2_{pred} = coeficiente de correlação da predição; RMSEC = raiz quadrada do erro quadrático médio de calibração (*Root Mean Square Error of Calibration*); RMSECV = raiz quadrada do erro quadrático médio de calibração cruzada (*Root Mean Square Error of Cross Validation*); RMSEP = raiz quadrada do erro quadrático médio de predição (*Root Mean Square Error of Prediction*).




Figura 2. Modelo de calibração multivariada por SVR para Fósforo Total

NRMSE, o que inviabilizou a comparação direta entre os erros dos modelos, uma vez que foram utilizadas as métricas de avaliação por RMSEC, RMSECV e RMSEP. No entanto, o modelo SVR obteve maior coeficiente de regressão em relação ao modelo quadrático, entendido como melhor desempenho.

Xiong *et al.* (2022) utilizaram as imagens registradas pelo satélite MODIS (*Moderate Resolution Imaging Spectroradiometer*) Aqua Level-1 para desenvolver um modelo de aprendizagem de máquina BST (*Extremely Gradient Boosting*),³⁶ relacionando os dados medidos em campo com as intensidades das bandas do vermelho e do infravermelho próximo (NIR) e médio (MIR), usadas para calcular o Índice de Algas Flutuantes. Embora o modelo descrito pelos autores tenha demonstrado respostas satisfatórias, tais como R^2 0,64 e RMSE 60,0 ($\mu\text{g L}^{-1}$), o desempenho foi inferior quando comparado ao modelo SVR.

Lyu *et al.* (2022) desenvolveram um modelo de regressão linear simples, a partir dos sinais espectrais adquiridos no espectrorradiômetro portátil ASD FieldSpec®,³⁷ para prever a concentração de fósforo total. A variável preditora desta regressão obedeceu a seguinte relação: $[(R_{443} + R_{710})/R_{575}]$, onde R é a representação da intensidade espectral em determinado comprimento de onda (nm). O modelo linear apresentou R^2 0,77 e RMSE 17,0 ($\mu\text{g L}^{-1}$), ou seja, um resultado considerado inferior ao modelo SVR.

Para estimar o parâmetro Turbidez (Turb), o modelo SVR também apresentou bons resultados (R^2_{cal} 0,962; R^2_{cv} 0,887; R^2_{pred} 0,984), RMSEC 1,219 UNT, RMSECV 2,184 UNT e RMSEP 1,467 UNT. O modelo SVR para turbidez está descrito na Figura 3.

Hossain *et al.* (2021) testaram três tipos de modelos (linear, exponencial e de potência) para predição da turbidez usando a reflectância das bandas do satélite Landsat-8 (B1 a B7).¹⁸ Os pesquisadores indicaram o modelo de potência como mais adequado (R^2 0,950; RMSE 11,47 UNT), que foi construído com os valores de reflectância da região do vermelho (B4). O modelo de potência apresentou

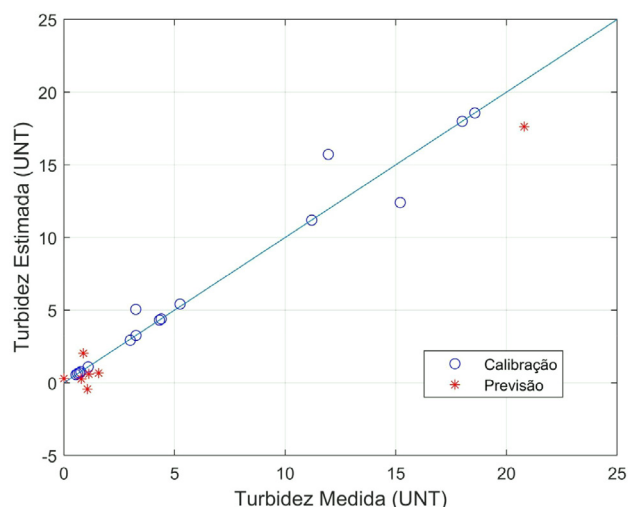


Figura 3. Modelo de calibração multivariada por SVR para Turbidez

desempenho similar ao encontrado com a calibração por SVR. Outro ponto importante diz respeito à relevância das bandas espectrais na região do vermelho e verde para o desenvolvimento de ambos os modelos, como evidenciado pelas melhores respostas de correlação de Pearson (Tabela 4), dados que foram utilizados na construção do modelo SVR.

De maneira análoga, Piwiset *et al.* (2022) desenvolveram diversos modelos de regressão, em que a melhor resposta foi obtida por meio da equação de potência usando como variável a banda B4 (R^2 0,823; RMSE 0,288 UNT).³⁸ Foi constatado que o erro obtido por Piwiset *et al.* (2022) foi quase quatro vezes maior quando comparado ao modelo de Hossain *et al.* (2021).^{18,38}

Wang *et al.* (2021) testaram diferentes métodos de correção atmosférica para prever a turbidez em sistemas lacustres e apontaram que o tipo de correção interfere diretamente nos resultados.³⁹ Os autores consideraram que a correção MUMM (*Management Unit of the North Seas Mathematical Models*), utilizando a razão entre as bandas B8/B3 em um modelo de potência, com R^2 0,780 e RMSE 24,097 (mg L^{-1}).

Para determinar o parâmetro Transparência (SDD), o modelo SVR resultou em um desempenho relativamente inferior às demais previsões (R^2_{cal} 0,584; R^2_{cv} 0,419; R^2_{pred} 0,705; RMSEC 1,059 m; RMSECV 1,258 m; RMSEP 0,785 m). Jaskula e Sojka (2019) estimaram este mesmo parâmetro por regressão linear simples, empregando a razão entre a intensidade de reflectância no azul dividida pelo vermelho (B2/B4).⁴⁰ A regressão univariada apresentou melhor linearidade (R^2 0,830) e maior valor de erro (RMSE 0,16 m), ou seja, demonstrou menor capacidade de predição quando comparada ao modelo multivariado. Mushtaq, Nee Lala e Mantoo (2022) aplicaram os sinais de reflectância do infravermelho próximo como variável preditora em um modelo exponencial e estimaram a transparência com o menor erro identificado na literatura (R^2 0,840; RMSE 0,11 m).⁵ O modelo SVR para transparência está descrito na Figura 4.

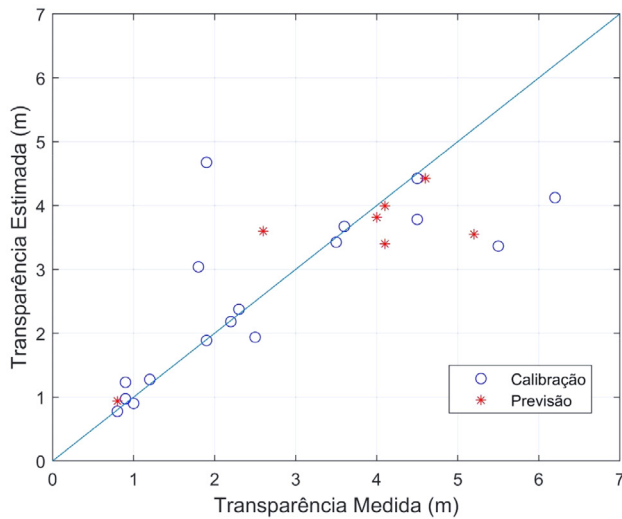


Figura 4. Modelo de calibração multivariada por SVR para Transparência

Para a concentração de clorofila-a (Chla), o modelo SVR apresentou resultados satisfatórios com R^2_{cal} 0,350; R^2_{cv} 0,293; R^2_{pred} 0,850; RMSEC 1,264 ($\mu\text{g L}^{-1}$); RMSECV 1,305 ($\mu\text{g L}^{-1}$) e RMSEP 0,457 ($\mu\text{g L}^{-1}$). Mushtaq, Nee Lala e Mantoo (2022) estimaram a clorofila-a com o modelo linear usando como variável os sinais das reflectâncias da banda do infravermelho próximo subtraída do sinal da reflectância do azul dividido pelo sinal da banda do verde $[(\rho_{w_{865}} - \rho_{w_{482}}) / \rho_{w_{561}}]$ com R^2 0,89 e RMSE 0,77 ($\mu\text{g L}^{-1}$), onde ρ_w é a representação da intensidade espectral em determinado comprimento de onda (nm).⁵ O trabalho de Mushtaq, Nee Lala e Mantoo (2022) confirma os resultados das correlações de Pearson apresentadas na Tabela 4, evidenciando que os maiores valores de correlação foram as mesmas bandas espectrais utilizadas para a construção do modelo elaborado por estes autores. Outro fator importante é de que o erro de predição obtido pelo presente trabalho é maior do que o erro encontrado no modelo desenvolvido.⁵ Lyu *et al.* (2022) estimaram Chla utilizando o modelo exponencial, utilizando como variável a razão entre os sinais de reflectância na região do vermelho em 710 nm por 680 nm, pois neste comprimento de onda, foi encontrada maior correlação pelos autores.³⁷ Foi obtido R^2 0,88 e RMSE 1,534 ($\mu\text{g L}^{-1}$), ou seja, apresentou maior linearidade, mas também erro de predição superior. Já Hossen *et al.* (2022) desenvolveram um modelo quadrático para prever Chla, utilizando como variável a razão dos sinais da banda do verde pelo infravermelho próximo do satélite Sentinel-2, obtendo R^2 0,83 e NRMSE 0,14 ($\mu\text{g L}^{-1}$), indicando similaridade com os resultados deste trabalho.⁴ Bu *et al.* (2022) utilizaram o modelo quadrático com a variável descritora $(B3-B4)/(B2+B3)$, ou seja, sendo os sinais espectrais do vermelho subtraída pelo infravermelho próximo dividido pelo banda do verde somada ao sinal da banda do vermelho, obtendo R^2 0,91 e RMSE 0,175 ($\mu\text{g L}^{-1}$), ou seja, o melhor desempenho comparado aos modelos aqui apresentados para esta variável.⁴¹ O modelo SVR para Chla está descrito na Figura 5.

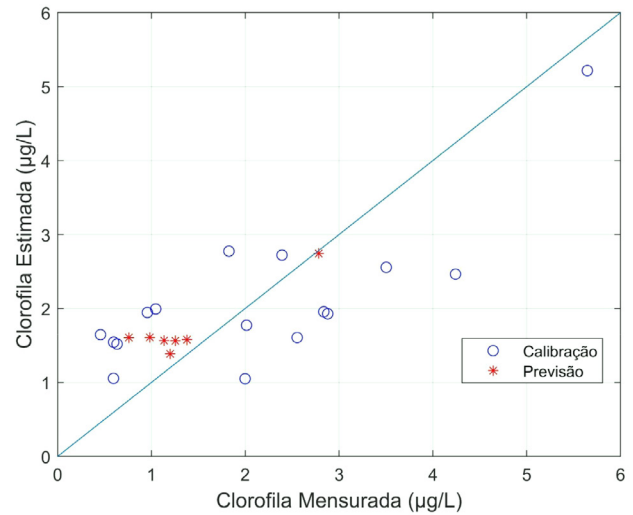


Figura 5. Modelo de calibração multivariada por SVR para clorofila-a

Para o IET, foi observado o comportamento sinérgico dos parâmetros avaliados descritos por Lyu *et al.* (2022).³⁷ O aumento da concentração de fósforo total em água evidencia a disponibilidade de nutrientes, proporcionando o ambiente perfeito para a proliferação de algas e a sua perpetuação, o que provoca o aumento na concentração de clorofila-a, seguida pela diminuição da transparência. Águas que possuem alta turbidez, relacionada ao material particulado suspenso de origem mineral como silte e argila, geralmente produzidos por intemperismo devido aos fatores climáticos e geológicos, como ventos, regime de chuvas e material sedimentar de fundo, dificultam a realização de fotossíntese do fitoplâncton na coluna d'água, o que leva a uma diminuição da concentração de clorofila-a. Neste sentido, apesar de haver a disponibilidade de nutrientes, o fator limitante do processo de eutrofização é a transparência da coluna d'água. Pode-se verificar pela Tabela 3, os altos valores para o IET(TP), enquanto, baixos valores para IET(Chla) e a transparência apresenta valores mais próximos do IET(Médio).

Na Figura 6, apresenta-se o modelo de calibração multivariada usando SVR para estimar o IET, e na Tabela 7, estão as classificações de IET que foram calculadas a partir do modelo de Carlson e os valores estimados pelo modelo SVR. Ao comparar as respostas atribuídas para cada lago, ficou constatado que apenas uma amostra foi classificada diferentemente, ou seja, a classificação do estado trófico a partir das amostras teste do modelo de regressão para o IET(Médio) apresentou aproximadamente 15 % de erro, o que se considera aceitável, tendo como referencial imagens de satélite.

Os lagos, de maneira geral, apresentaram-se no estado mesotrófico, estágio de transição e de alerta. A disponibilidade de fósforo apresentadas pelos lagos é um fator preocupante, pois indica que a concentração de clorofila-a ainda pode chegar a valores maiores, o que desencadearia em um processo de eutrofização mais elevado.

Essas avaliações evidenciam a importância da realização

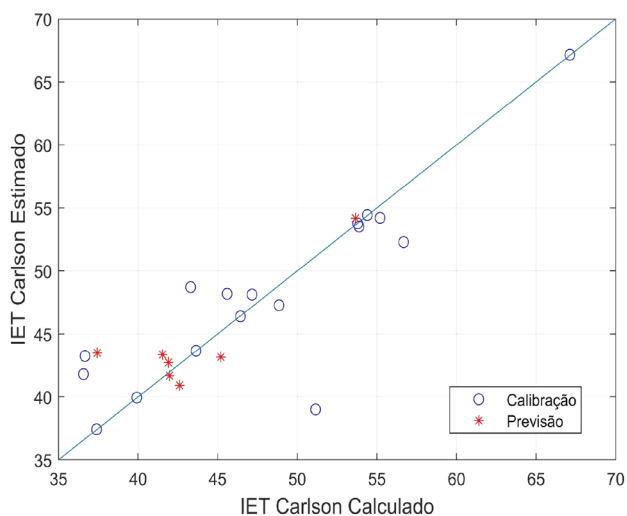


Figura 6. Modelo de calibração multivariada por SVR para IET Carlson

do monitoramento ambiental, pois auxiliam na tomada de decisão na gestão destes recursos hídricos, conduzindo para ações mais efetivas nas medidas de contingenciamento do processo de eutrofização.

Na Tabela 8 foi elaborado um quadro de comparação de modelos estudados na literatura para estimação desses parâmetros.

Os modelos SVR do presente estudo representam avanços significativos para o monitoramento por sensoriamento remoto da qualidade de água e do processo de eutrofização em lagos intermitentes, uma vez que demonstraram equivalência aos modelos de predição encontrados na literatura e, por vezes, certa superioridade analítica, principalmente no que tange à verificação da precisão dos resultados e da robustez do modelo, por calcular as figuras de mérito.

A limitação do potencial de predição dos modelos SVR

Tabela 7. Classificação do estado trófico e resultados do Índice de Estado Trófico (IET) calculado pelo modelo de Carlson, usando medidas de campo, e estimados pela regressão por SVR com os espectros

IET calculado por Carlson	Classificação Carlson	IET estimado por SVR	Classificação SVR
42,61	Mesotrófico	43,84	Mesotrófico
41,91	Mesotrófico	44,75	Mesotrófico
41,97	Mesotrófico	44,63	Mesotrófico
53,65	Eutrófico	52,37	Eutrófico
45,20	Mesotrófico	45,19	Mesotrófico
37,43	Oligotrófico	45,39	Mesotrófico
41,54	Mesotrófico	45,40	Mesotrófico

Legenda: SVR = Regressão por Vetores de Suporte (*Support Vector Regression*); IET = Índice de Estado Trófico.

Tabela 8. Modelos de predição encontrados na literatura para as propriedades limnológicas

Equação do modelo de predição	Propriedades	R ² _{cal}	RMSE _v	Referência
TP=36,201x ² +92,078x+230,74; x=(B8/B3)	TP	0,733	0,16	[4]
TP=-0,023+5,02(B5)	TP	0,670	NE	[42]
TP= <i>Extremely Gradient Boosting (BST)</i>	TP	0,640	60,0	[36]
TP=0,136x ² -0,284x+0,234; x=[(R ₄₄₃ +R ₇₁₀)/R ₅₇₅]	TP	0,770	17,0	[37]
Turb=2677,2(B4) ^{1,856}	Turb	0,950	11,47	[18]
Turb=1509,984(B4) ^{1,7241}	Turb	0,823	0,288	[38]
Turb=610,210(B8/B3) ^{1,705}	Turb	0,780	24,097	[39]
Turb=2100,3(B4)-186,3	Turb	0,850	2,00	[43]
SDD=-52,8637+975533(B2/B4)	SDD	0,830	0,16	[40]
SDD=0,01e ^{0,51(x)} ; x=R ₈₆₅	SDD	0,840	0,11	[5]
SDD=-0,677x+1,332; x=[(R ₄₄₃ +R ₇₁₀)/R ₅₇₅]	SDD	0,807	0,09	[37]
SDD=673,05x ² -1122x+491,84; x=(B6/B7)	SDD	0,519	0,03	[4]
Chla=62,24x+126,27; x=[(R ₈₆₅ -R ₄₈₂)/R ₅₆₁]	Chla	0,890	0,770	[5]
Chla=0,0003e ^(0,974x) +0,410; x=(R ₇₁₀ /R ₆₈₀)	Chla	0,885	1,534	[37]
Chla=576,51x ² -1126,6x+583,14; x=(B7/B8)	Chla	0,835	0,140	[4]
Chla=66,27x ² -14,751x+3,3302; x=[(B3-B4)/(B2+B3)]	Chla	0,909	0,1752	[41]

Legenda: NE = não estabelecido; TP = Fósforo Total (µg L⁻¹); R = intensidade espectral em determinado comprimento de onda (nm); Turb = Turbidez, sendo (UNT)^{18,38} e (mg L⁻¹)^{39,43}; SDD = Transparência (m); Chla = Clorofila-a (µg L⁻¹); R²_{cal} = coeficiente de correlação da calibração; RMSE_v = raiz quadrada do erro quadrático médio (*Root Mean Square Error*), considerando os resultados de validação dos trabalhos.

deve-se a presença de nuvens sobre a área espacial dos lagos estudados e também da diferença entre o período amostral em campo e a data do registro da imagem pelo satélite Landsat-8, devido a resolução temporal do sensor ocorrer em ciclos de 16 dias. Estes fatores limitaram a construção do banco de dados para o desenvolvimento dos modelos SVR, no entanto, verifica-se a funcionalidade como bons indicadores para o monitoramento da qualidade de água em lagos intermitentes e, logo, para a classificação do processo de eutrofização, de forma 100 % remota.

4. Conclusões

Neste estudo foram desenvolvidos modelos quimiométricos de regressão multivariada SVR por meio das imagens do satélite Landsat-8 OLI com dados limnológicos, utilizando as bandas de reflectância da região do visível e do infravermelho próximo, por ser a faixa do espectro em que a água reflete parte da energia eletromagnética, para estimar os parâmetros de qualidade da água: fósforo total, turbidez, transparência e clorofila-a. O sensoriamento remoto através do uso de ferramentas quimiométricas para o monitoramento de corpos d'água demonstram resultados promissores e, por vezes, mais vantajosos em relação aos trabalhos da literatura, por isto, trata-se de um método recomendado por apresentar maior robustez e critérios de confiabilidade.

Os resultados apontam que os lagos Juparanã e Nova estão em estágio intermediário de eutrofização, devido aos altos níveis de fósforo total, porém, em função aos altos valores de turbidez, as elevadas concentrações de clorofila-a são consideradas aceitáveis, sugerindo que a transparência exerça o controle do equilíbrio hidrodinâmico nestes lagos.

A calibração multivariada por SVR com uso de dados espectrais do sensoriamento remoto consegue indicar a classificação do Índice de Estado Trófico (IET) para sete amostras de lagos intermitentes, e destas apenas uma resposta não coincide com o dado pelo modelo de Carlson. O monitoramento do processo de eutrofização em lagos intermitentes pode ser realizado remotamente com uso de dados obtidos pelo satélite Landsat-8 e aplicados no modelo SVR.

Agradecimentos

Os autores agradecem à UFES, ao NCQP/LABPETRO, à RRDM e à Fundação Renova pelo fornecimento dos dados e também pelo apoio na execução do projeto. Os autores reconhecem a relevância da bolsa de pesquisa da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) - Brasil - Código de Financiamento 001. Os autores declaram não haver conflitos de interesses que possam ter influenciado este estudo.

Referências Bibliográficas

1. Kirk, J. T. O.; *Light and photosynthesis in aquatic ecosystems*, 3a. ed., Cambridge University Press: Cambridge, 2011.
2. Machado, M. T. S.; Baptista, G. M. M.; Sensoriamento remoto como ferramenta de monitoramento da qualidade da água do Lago Paranoá (DF). *Engenharia Sanitária e Ambiental* **2016**, *21*, 357. [Crossref]
3. Schäfer, A.; *Fundamentos da ecologia e biogeografia das águas continentais*, 1a. ed., UFRGS: Porto Alegre, 1985.
4. Hossen, H.; Mahmood, W. E.; Negm, A.; Nakamura, T.; Assessing Water Quality Parameters in Burullus Lake Using Sentinel-2 Satellite Images. *Water Resources* **2022**, *49*, 321. [Crossref]
5. Mushtaq, F.; Nee Lala, M. G.; Mantoo, A. G.; Trophic State Assessment of a Freshwater Himalayan Lake Using Landsat 8 OLI Satellite Imagery: A Case Study of Wular Lake, Jammu and Kashmir (India). *Earth and Space Science* **2022**, *9*, e2021EA001653. [Crossref]
6. Sítio do Instituto Capixaba de Pesquisa, Assistência Técnica e Extensão Rural (Incaper). Disponível em: <<https://meteorologia.incaper.es.gov.br/graficos-da-serie-historica-linhares>>. Acesso em: 12 julho 2022.
7. Coutinho, J. M. V.; *Resumos do 28º Congresso Brasileiro de Geologia*, Porto Alegre, Brasil, 1974. [Link]
8. Barroso, G. F.; Gonçalves, M. A.; Garcia, F. C.; The morphometry of Lake Palmas, a deep natural Lake in Brazil. *PLoS ONE* **2014**, *9*, e111469. [Crossref]
9. Gonçalves, M. A.; Garcia, F. C.; Barroso, G. F.; Morphometry and mixing regime of a tropical lake: Lake Nova (Southeastern Brazil). *Anais da Academia Brasileira de Ciências* **2016**, *88*, 1341. [Crossref]
10. Bozelli, R. L.; Esteves, F. A.; Roland, F.; Suzuki, M. S.; Padrões de funcionamento das lagoas do Baixo Rio Doce: variáveis abióticas e clorofila-a (Espírito Santo-Brasil). *Acta Limnologica Brasiliensia* **1992**, *4*, 13. [Link]
11. Gonçalves, M. A.; *Tese de Doutorado*, Universidade Federal do Espírito Santo, 2015. [Link]
12. Sítio da Rede Rio Doce Mar (RRDM). Disponível em: <<http://rrdm.net.br>>. Acesso em: 12 julho 2019.
13. Thebit-Almeida, L.; Bernardes-Silva, F.; Fraga, M. S.; Balieiro-Ribeiro, R.; Alves-Ramos, M. C.; Avelino-Cecílio, R.; Análise do comportamento espectral da água do Rio Doce, Brasil, mediante o rompimento da barragem de sedimentos da empresa SAMARCO. *Revista Tecnologia em Marcha* **2019**, *32*, 36. [Crossref]
14. Sathyendranath, S.; Cota, G.; Stuart, V.; Maass, H.; Platt, T.; Remote sensing of phytoplankton pigments: A comparison of empirical and theoretical approaches. *International Journal of Remote Sensing* **2001**, *22*, 249. [Crossref]
15. Pereira, R.; *Dissertação de Mestrado*, Universidade Federal do Rio Grande do Sul, 2007. [Link]
16. Ekstrand, S.; Landsat TM based quantification of chlorophyll-a during algae blooms in coastal waters. *International Journal of Remote Sensing* **1992**, *13*, 1913. [Crossref]
17. Ekercin, S.; Water quality retrievals from high resolution

- IKONOS multispectral imagery: A case study in Istanbul, Turkey. *Water, Air, and Soil Pollution* **2007**, *183*, 239. [Crossref]
18. Hossain, A. K. M. A.; Mathias, C.; Blanton, R.; Remote Sensing of Turbidity in the Tennessee River Using Landsat 8 Satellite. *Remote Sensing* **2021**, *13*, 3785. [Crossref]
 19. Wang, F.; Han, L.; Kung, H.-T.; Van Arsdale, R. B.; Applications of Landsat-5 TM imagery in assessing and mapping water quality in Reelfoot Lake, Tennessee. *International Journal of Remote Sensing* **2006**, *27*, 5269. [Crossref]
 20. Lu, L.; Gong, Z.; Liang, Y.; Liang, S.; Retrieval of Chlorophyll-a Concentrations of Class II Water Bodies of Inland Lakes and Reservoirs Based on ZY1-02D Satellite Hyperspectral Data. *Remote Sensing* **2022**, *14*, 1842. [Crossref]
 21. AL-Fahdawi, A. A. H.; Rabee, A. M.; Al-Hirmizy, S. M.; Water quality monitoring of Al-Habbaniyah Lake using remote sensing and in situ measurements. *Environmental Monitoring and Assessment* **2015**, *187*, 367. [Crossref]
 22. Rudorff, N.; Rudorff, C. M.; Kampel, M.; Ortiz, G.; Remote sensing monitoring of the impact of a major mining wastewater disaster on the turbidity of the Doce River plume off the eastern Brazilian coast. *ISPRS Journal of Photogrammetry and Remote Sensing* **2018**, *145*, 349. [Crossref]
 23. Filgueiras, P. R.; Alves, J. C. L.; Poppi, R. J.; Quantification of animal fat biodiesel in soybean biodiesel and B20 diesel blends using near infrared spectroscopy and synergy interval support vector regression. *Talanta* **2014**, *119*, 582. [Crossref]
 24. Skou, P. B.; Berg, T. A.; Aunsbjerg, S. D.; Thaysen, D.; Rasmussen, M. A.; van den Berg, F.; Monitoring Process Water Quality Using Near Infrared Spectroscopy and Partial Least Squares Regression with Prediction Uncertainty Estimation. *Applied Spectroscopy* **2017**, *71*, 410. [Crossref]
 25. Rainha, K. P.; Rocha, J. T. C.; Rodrigues, R. R. T.; Lovatti, B. P. O.; Castro, E. V. R.; Filgueiras, P. R.; Determination of API Gravity and Total and Basic Nitrogen Content by Mid- and Near-Infrared Spectroscopy in Crude Oil with Multivariate Regression and Variable Selection Tools. *Analytical Letters* **2019**, *52*, 2914. [Crossref]
 26. Folli, G. S.; Nascimento, M. H. C.; De Paulo, E. H.; Cunha, P. H. P.; Romão, W.; Filgueiras, P. R.; Variable selection in support vector regression using angular search algorithm and variance inflation factor. *Journal of Chemometrics* **2020**, *34*, 3282. [Crossref]
 27. Santos, F. D.; Santos, L. P.; Cunha, P. H. P.; Borghi, F. T.; Romão, W.; Castro, E. V. R.; De Oliveira, E. C.; Filgueiras, P. R.; Discrimination of oils and fuels using a portable NIR spectrometer. *Fuel* **2021**, *283*, 118854. [Crossref]
 28. Drucker, H.; Burges, C. J. C.; Kaufman, L.; Smola, A.; Vapnik, V.; Em *Advances in Neural Information Processing Systems 9 (NIPS 1996)*; Mozer, M. C.; Jordan, M.; Petsche, T., eds.; MIT Press: Cambridge, 1997. [Link]
 29. Valderrama, J. C.; The simultaneous analysis of total nitrogen and total phosphorus in natural waters. *Marine Chemistry* **1981**, *10*, 109. [Crossref]
 30. APHA - American Public Health Association; *Standard methods for the examination of water and wastewater*, 21st ed., APHA: Washington, 2005.
 31. Carlson, R. E.; A trophic state index for lakes. *Limnology and Oceanography* **1977**, *22*, 361. [Crossref]
 32. Sítio do United States Geological Survey (USGS) pela interface EarthExplorer. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 19 maio 2022.
 33. Jensen, J. R.; *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*, 2a. ed., Parêntese: São José dos Campos, 2009.
 34. Vermote, E.; Justice, C.; Claverie, M.; Franch, B.; Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment* **2016**, *185*, 46. [Crossref]
 35. Costa, M. P. F.; Galvão, S. M. G.; Novo, E. M. L. M.; *Resumos do IX Simpósio Brasileiro de Sensoriamento Remoto*, Santos, Brasil, 1998. [Link]
 36. Xiong, J.; Lin, C.; Cao, Z.; Hu, M.; Xue, K.; Chen, X.; Ma, R.; Development of remote sensing algorithm for total phosphorus concentration in eutrophic lakes: Conventional or machine learning? *Water Research* **2022**, *215*, 118213. [Crossref]
 37. Lyu, L.; Song, K.; Wen, Z.; Liu, G.; Shang, Y.; Li, S.; Tao, H.; Wang, X.; Hou, J.; Estimation of the lake trophic state index (TSI) using hyperspectral remote sensing in Northeast China. *Optics Express* **2022**, *30*, 10329. [Crossref]
 38. Pimwiset, W.; Tungkananuruk, K.; Rungratanaubon, T.; Kullavanijaya, P.; Veesommai Sillberg, C.; Water Turbidity Determination by a Satellite Imagery-Based Mathematical Equation for the Chao Phraya River. *Environment and Natural Resources Journal* **2022**, *20*, 297. [Crossref]
 39. Wang, H.; Wang, J.; Cui, Y.; Yan, S.; Consistency of suspended particulate matter concentration in turbid water retrieved from Sentinel-2 MSI and Landsat-8 OLI sensors. *Sensors* **2021**, *21*, 1662. [Crossref]
 40. Jaskula, J.; Sojka, M.; Application of Remote Sensing and GIS to Water Transparency Estimation in Reservoirs. *Carpathian Journal of Earth and Environmental Sciences* **2019**, *14*, 353. [Crossref]
 41. Bu, J.; Cai, L.; Yan, X.; Xu, H.; Hu, H.; Jiang, J.; Monitoring the Chl-a Distribution Details in the Yangtze River Mouth Using Satellite Remote Sensing. *Water* **2022**, *14*, 1295. [Crossref]
 42. Su, P. W.; Lo, S. L.; Using Landsat 8 imagery for remote monitoring of total phosphorus as a water quality parameter of irrigation ponds in Taiwan. *Environmental Science and Pollution Research* **2021**, *28*, 66687. [Crossref]
 43. Tarasov, M. K.; Tutubalina, O. V.; Estimating the water turbidity in the Selenga River and adjacent waters of Lake Baikal using remote sensing data. *Izvestiya, Atmospheric and Oceanic Physics* **2018**, *54*, 1353. [Crossref]