

UNIVERSIDADE FEDERAL DE MINAS GERAIS

Instituto de Geociências

Programa de Pós-graduação em Geografia

**MODELOS DE TURBIDEZ, TRANSPARÊNCIA E
CONCENTRAÇÃO DE CLOROFILA NO
RESERVATÓRIO DE TRÊS MARIAS A PARTIR DOS
DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2**

Fernanda Mara Coelho Pizani

Belo Horizonte

2023

Fernanda Mara Coelho Pizani

**MODELOS DE TURBIDEZ, TRANSPARÊNCIA E
CONCENTRAÇÃO DE CLOROFILA NO
RESERVATÓRIO DE TRÊS MARIAS A PARTIR DOS
DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2**

Tese de Doutorado apresentada ao Programa
de Pós-graduação do Departamento de
Geografia da Universidade Federal de Minas
Gerais, como requisito parcial à obtenção do
título de Doutora em Geografia.

Área de Concentração: Análise Ambiental

Orientador: Prof. Dr. Philippe Maillard

Belo Horizonte
2023

P695m Pizani, Fernanda Mara Coelho.
2023 Modelos de turbidez, transparência e concentração de clorofila no Reservatório de Três Marias a partir dos dados espectrais dos satélites Sentinel-2 [manuscrito] / Fernanda Mara Coelho Pizani. – 2023.
272 f., enc.: il. (principalmente color.)
Orientador: Philippe Maillard.
Tese (doutorado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2023.
Área de concentração: Análise Ambiental.
Bibliografia: f. 131-148.
Inclui apêndices e anexos.
1. Sensoriamento remoto – Teses. 2. Água – Qualidade – Três Marias, Reservatório de (MG) – Teses. 3. Recursos hídricos – Teses. 4. Imagens multiespectrais – Teses. 5. Análise de regressão – Teses. I. Maillard, Philippe. II. Universidade Federal de Minas Gerais. Instituto de Geociências. III. Título.

CDU: 528.8:556.5(815.1)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
PÓS-GRADUAÇÃO EM GEOGRAFIA

FOLHA DE APROVAÇÃO

"MODELOS DE TURBIDEZ, TRANSPARÊNCIA E CONCENTRAÇÃO DE CLOROFILA NO RESERVATÓRIO DE TRÊS MARIAS A PARTIR DOS DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2"

FERNANDA MARA COELHO PIZANI

Tese de Doutorado defendida e aprovada, no dia **26 de abril de 2023**, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Geografia da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

Rodrigo Cauduro Dias de Paiva

UFRGS

Lino Augusto Sander de Carvalho

UFRJ

Adolf Heinrich Horn

UFMG

Talita Fernanda das Graças Silva

UFMG

Fábio Soares de Oliveira

IGC/UFMG

Philippe Maillard - Orientador

IGC/UFMG

Belo Horizonte, 26 de abril de 2023.



Documento assinado eletronicamente por **Talita Fernanda das Gracas Silva, Professora do Magistério Superior**, em 04/05/2023, às 13:47, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Adolf Heinrich Horn, Professor do Magistério Superior**, em 04/05/2023, às 14:36, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabio Soares de Oliveira, Professor do Magistério Superior**, em 04/05/2023, às 15:32, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Philippe Maillard, Professor do Magistério Superior**, em 04/05/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lino Augusto Sander de Carvalho, Usuário Externo**, em 15/05/2023, às 16:00, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rodrigo Cauduro Dias de Paiva, Usuário Externo**, em 24/05/2023, às 11:53, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2174891** e o código CRC **D3A5BE8E**.

Agradecimentos

O CAMINHO acadêmico não se iniciou em 2019, quando eu ingressava no doutorado. Iniciou-se em 2005 quando, ainda jovem, buscava naquele curso de Geografia compreender a dinâmica e os rumos que a vida iria me proporcionar no futuro. E aqui estou, parcialmente incrédula que aquela menina carregada de esperanças agora concretiza o que um dia foi sonho. Para chegar até aqui muitos foram os desafios que não superei sozinha.

Agradeço aos meus pais e aos meus irmãos que são parte de mim. Para nós, desistir nunca foi uma opção. Vocês são meus exemplos de força e caráter.

Ao meu esposo, Fernando Pizani, que me deu suporte emocional nesta jornada e me apoiou nos, não raros, momentos difíceis. São doze anos, mas cabem três vidas inteiras.

À UFMG e aos professores do Instituto de Geociências por todo ensinamento. À Banca Examinadora, por aceitar o convite e pelas importantes contribuições. Aos colegas de classe pelas experiências compartilhadas ao longo destes quatro anos.

Ao meu orientador, Prof. Dr. Philippe Maillard pelos ensinamentos e instruções. Você é um exemplo de docente, pesquisador e orientador que eu acredito. Abrir as portas do Laboratório de Sensoriamento Remoto, dedicar incontáveis horas para que a minha experiência fosse a mais profunda possível e permitir que eu fosse parte daquele universo durante todo este período foram atos de cuidado indescritíveis.

Aos amigos mais próximos, que sempre me acompanharam, e àqueles que fiz no IGC. Obrigada pela convivência e por fazerem parte do meu desenvolvimento.

À Companhia Energética de Minas Gerais (CEMIG), ao P&D CEMIG ANEEL “Monitoramento inteligente da qualidade da água em reservatórios hidrelétricos através do desenvolvimento de um algoritmo fotogramétrico”, em especial ao GT-607 e à coordenadora Prof.a. Dr.a. Camila Costa Amorim. Sem o apoio de vocês esta pesquisa não seria possível. À Fundação de Desenvolvimento da Pesquisa pela concessão da bolsa de estudos em nível de doutorado.

Enfim, a todos que acreditaram em mim, muito obrigada. Vocês me motivaram. E aos que duvidaram de mim, muito obrigada. Vocês me motivaram também.

“Cada um de nós compõe a sua história
e cada ser em si carrega o dom de ser capaz.
E ser feliz.”

(Almir Sater – Tocando em Frente, 1992)

Resumo

A MAIOR parte dos estudos de sensoriamento remoto envolvendo a qualidade da água é aplicado a ambientes hídricos consideravelmente turvos ou altamente eutrofizados. O Reservatório de Três Marias é um ambiente considerado de águas claras sendo classificado como ultraoligotrófico a oligotrófico, o que é parte do desafio do estudo. O principal objetivo do trabalho consistiu em desenvolver modelos empíricos para águas claras a fim de estimar parâmetros opticamente ativos da água no Reservatório de Três Marias permitindo sua caracterização distribuída e sistemática a partir de dados de sensoriamento remoto (missão Sentinel-2). Três parâmetros foram considerados: turbidez, profundidade do disco de Secchi e clorofila-a. A primeira etapa investigou a relação entre dados medidos *in situ* dos componentes opticamente ativos e a reflectância espectral nas imagens ópticas do sensor MSI dos satélites Sentinel-2A e -2B. Os resultados comprovaram a característica do reservatório como um ambiente de águas claras a moderadamente claras com maior reflectância espectral no comprimento de onda 560 nm (verde). Com o auxílio de análises estatísticas, na segunda etapa modelou-se os três parâmetros por técnicas empíricas. Foram testados modelos de regressão simples e múltipla usando bandas do MSI e outros modelos reconhecidos na literatura internacional especializada. A abordagem permitiu propor o modelo com melhor desempenho para cada um dos parâmetros, incluindo um modelo próprio para a turbidez em águas claras. Foi concluído que modelos simples são capazes de estimar os parâmetros ópticos de qualidade da água no reservatório e de determinar como a dinâmica espacial pode variar no tempo. A terceira fase se caracterizou pela calibração e validação dos modelos selecionados. Foram selecionados dois pontos específicos do reservatório (montante e jusante) para calibrar os modelos. Os resultados obtidos utilizando o conjunto total de dados para turbidez ($r^2 = 0,80$, RMSE = 0,74 FNU), transparência ($r^2 = 0,95$, RMSE = 0,70 m) e clorofila-a ($r^2 = 0,64$, RMSE = 1,24 $\mu\text{g/L}$) foram considerados muito bons, excelentes e médio respectivamente. A abordagem proposta foi testada no reservatório Várzea das Flores onde foram adquiridos dados de qualidade da água retornando modelos com bons ajustes para turbidez ($r^2 = 0,62$, RMSE = 2,46 FNU), transparência ($r^2 = 0,94$, RMSE = 0,31 m) e clorofila-a ($r^2 = 0,80$, RMSE = 0,78 $\mu\text{g/L}$). A pesquisa evidencia que o monitoramento ambiental aquático por sensoriamento remoto não substitui medições *in situ* periódicas, porém permite complementar as medições facilitando o acompanhamento da dinâmica temporal. O sensoriamento remoto e suas tecnologias relacionadas oferecem enormes perspectivas para o monitoramento operacional de reservatórios.

Palavras-chave: Sensoriamento remoto aquático; Qualidade da água; Reservatório; Componentes opticamente ativos; Reflectância espectral; Análise de regressão.

Abstract

MOST studies of remote sensing involving water quality are applied to water environments that are considerably turbid or highly eutrophic. Três Marias Reservoir is a clear water environment and is classified as ultraoligotrophic to oligotrophic, which is part of the challenge of the study. The main objective of this study consists in developing empirical models to estimate optically active water quality parameters of the Três Marias Reservoir in order to allow its evaluation in a distributed and systematic way from remote sensing data (Sentinel-2 mission). Three parameters were considered: turbidity, Secchi disk depth and chlorophyll-a. The first phase investigated the relationship between the concentration of optically active components measured *in situ* and the spectral reflectance of water from optical images obtained from the MSI sensor of the Sentinel-2A and -2B satellites. The results confirmed the characteristic of the reservoir as an environment of clear to moderately clear water, with higher spectral reflectance in the 560 nm wavelength (green). With the aid of statistical analyses, the second phase sought to model the three parameters by empirical techniques. Simple and multiple regression models were tested using the MSI bands and band combinations recognized in the specialized international literature. The approach allowed to propose the model with the best performance for each parameters, including a specific model developed for the turbidity of clear water environments. It was concluded that regression models are able to estimate the optical parameters of water quality in the reservoir and characterize how the spatial dynamics can vary over time. The third phase was characterized by the calibration and validation of the selected models. Two specific points of the reservoir (upstream and downstream) were selected to calibrate the models. The results obtained using the consolidated data set for turbidity ($r^2 = 0.80$, RMSE = 0.74 FNU), transparency ($r^2 = 0.95$, RMSE = 0.70 m) and chlorophyll-a ($r^2 = 0.64$, RMSE = 1.24 $\mu\text{g/L}$) were considered very good, excellent and average respectively. The proposed approach was tested in the Várzea das Flores reservoir where water quality data were acquired, which also returned models with good adjustments for turbidity ($r^2 = 0.62$, RMSE = 2, 46 FNU), transparency ($r^2 = 0.94$, RMSE = 0.31 m) and chlorophyll-a ($r^2 = 0.80$, RMSE = 0.78 $\mu\text{g/L}$). The research shows that the aquatic environmental monitoring by remote sensing cannot completely replace periodic *in situ* measurements, but it allows to considerably reduce the quantity and/or frequency of these measurements, facilitating the monitoring of the temporal dynamics of the water body. Remote sensing and its related technologies offer enormous perspectives for the operational monitoring of reservoirs.

Key words: Aquatic remote sensing; Water quality; Reservoirs; Optically active components; Spectral reflectance; Regression analysis.

Listas de Ilustrações

2.1	Impurezas contidas na água.	22
2.2	Histórico e previsão de lançamento de missões altimétricas.	25
2.3	Representação da radiância total captada pelo sensor em um corpo d'água.	27
2.4	Gráfico sobre os espectros de absorção e espalhamento nos comprimentos de onda visíveis para os constituintes bio-ópticos da água.	28
2.5	Espectros da água sob dominância de TSM.	36
2.6	Espectros da água sob dominância de chl-a.	39
2.7	Espectros da água sob dominância de CDOM.	41
2.8	Medição da transparência utilizando disco de Secchi.	43
2.9	Exemplos de imagens de turbidez da água registradas por sensores remotos orbitais a bordo de satélites.	45
2.10	Esquema da abordagem clássica para o processo de modelagem.	50
2.11	Etapas de desenvolvimento de um modelo matemático.	51
2.12	Passos necessário para a construção de um modelo de qualidade de água.	52
2.13	Fluxograma das principais etapas da modelagem dos constituintes da água.	53
3.1	Fluxograma metodológico.	58
3.2	Mapa de localização do Reservatório de Três Marias.	61
3.3	Embarcação utilizada para a amostragem limnológica na represa.	64
3.4	Distribuição dos pontos amostrais por campanha.	65
3.5	Método <i>Knock-out</i> para seleção de variáveis.	73
4.1	Classificação do uso e cobertura do solo do entorno do Reservatório de Três Marias. .	77
4.2	Presença de algas/cianobactérias observada próximo aos pontos 7 e 8.	78
4.3	Subcenas das oito imagens do Sentinel-2 (banda 8A – NIR) mostrando a diferença entre os níveis d'água do reservatório nas oito campanhas de campo.	79
4.4	Gráfico mostrando o nível da água durante os oito levantamentos de campo no Reservatório de Três Marias.	79
4.5	Comportamento espectral da água do Reservatório de Três Marias nos pontos mensurados durante as campanhas de campo.	81
4.6	<i>Boxplot</i> da turbidez para as campanhas de campo.	82

4.7	Relação entre turbidez e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.	83
4.8	Relação entre turbidez e feições derivadas dos modelos da literatura no Reservatório de Três Marias.	84
4.9	Gráfico da matriz de correlação para turbidez.	87
4.10	Variação dos coeficientes para turbidez.	92
4.11	Variação dos coeficientes para turbidez utilizando combinações das bandas do visível: a) $\beta_1\rho B2 + \beta_2\rho B3 + \beta_3\rho B4$; b) $\beta_1\rho B2 + \beta_2\rho B3$; c) $\beta_1\rho B2 + \beta_3\rho B4$ e; d) $\beta_2\rho B3 + \beta_3\rho B4$	92
4.12	Dados observados <i>vs.</i> dados preditos utilizando o índice NLTDI para o conjunto geral de dados.	94
4.13	Modelo de regressão utilizando o índice NLTDI para o conjunto geral de dados sem calibração.	95
4.14	Gráfico mostrando a diferença entre as concentrações medidas de turbidez e os valores obtidos pela calibração dos índices de dados Sentinel-2/MSI.	95
4.15	<i>Boxplot</i> da SDD para as campanhas de campo.	97
4.16	Relação entre SDD e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.	98
4.17	Relação entre SDD e feições derivadas dos modelos da literatura no Reservatório de Três Marias.	99
4.18	Gráfico da matriz de correlação para SDD.	100
4.19	Variação dos coeficientes para SDD (a) e detalhamento da variação dos coeficientes para SDD para as variáveis SDD_2 , SDD_3 e SDD_5 (b).	105
4.20	Dados observados <i>vs.</i> dados preditos utilizando o modelo SDD_2 para o conjunto geral de dados.	106
4.21	Dados observados <i>vs.</i> dados preditos utilizando o modelo SDD_5 para o conjunto geral de dados.	107
4.22	Modelo de regressão utilizando o modelo SDD_2 para o conjunto geral de dados sem calibração.	108
4.23	Modelo de regressão utilizando o modelo SDD_5 para o conjunto geral de dados sem calibração.	108
4.24	Gráfico mostrando a diferença entre a transparência medida e os valores obtidos pela calibração do modelo SDD_2 de dados Sentinel-2/MSI.	109
4.25	Gráfico mostrando a diferença entre a transparência medida e os valores obtidos pela calibração do modelo SDD_5 de dados Sentinel-2/MSI.	109
4.26	<i>Boxplot</i> da concentração de chl-a para as campanhas de campo.	111
4.27	Relação entre concentração de chl-a e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.	113
4.28	Relação entre chl-a e feições derivadas dos modelos da literatura no Reservatório de Três Marias.	114
4.29	Gráfico da matriz de correlação para chl-a.	116

4.30 Variação dos coeficientes para chl-a.	119
4.31 Dados observados <i>vs.</i> dados preditos utilizando o índice <i>Chla₅</i> para o conjunto geral de dados sem calibração.	121
4.32 Modelo de regressão utilizando o índice <i>Chla₅</i> para o conjunto geral de dados sem calibração.	121
4.33 Gráfico mostrando a diferença entre as concentrações medidas de chl-a e os valores obtidos pela calibração dos índices de dados Sentinel-2/MSI.	122
4.34 Mapas de turbidez das campanhas de campo utilizando o índice NLTDI calibrados em dois pontos.	123
4.35 Mapas de SDD das campanhas de campo utilizando o modelo <i>SDD₂</i> calibrados em dois pontos.	124
4.36 Mapas de chl-a das campanhas de campo utilizando o índice <i>Chla₅</i> calibrados em dois pontos.	125
4.37 Mapas de turbidez, SDD e chl-a no Reservatório Várzea das Flores. Os mapas foram produzidos usando os índices calibrados de dois pontos NLTDI, <i>SDD₂</i> e <i>Chla₅</i> . . .	127

Listas de Tabelas

2.1	Classificação dos corpos de águas doces.	24
2.2	Especificações de três sensores hiperespectrais: APEX, MIVIS e HySpex.	31
2.3	Sensores de satélites e veículos aerotransportados lançados após os anos 2000, frequentemente usados para avaliação de qualidade da água.	31
3.1	Os dez maiores reservatórios brasileiros de acordo com a área.	60
3.2	Os dez maiores reservatórios brasileiros de acordo com o volume.	60
3.3	Campanhas de campo e parâmetros medidos/coletados entre os anos de 2019 e 2021.	63
3.4	Descrição das bandas espectrais do sensor MSI/Sentinel-2.	66
3.5	Equações referentes aos modelos para estimativa de turbidez, SDD e chl-a baseadas nas bandas espectrais do sensor MSI.	70
3.6	Descrição das abordagens utilizadas para estimativa de turbidez nos estudos selecionados.	71
3.7	Descrição das abordagens utilizadas para estimativa de SDD nos estudos selecionados.	71
3.8	Descrição das abordagens utilizadas para estimativa de chl-a nos estudos selecionados.	72
4.1	Estatística descritiva dos resultados de qualidade da água no Reservatório de Três Marias.	78
4.2	Performance da avaliação dos modelos individuais para turbidez.	85
4.3	Matriz de correlação para turbidez.	88
4.4	Resultado da seleção de variáveis por <i>ranking</i> via <i>Knock-out</i> para turbidez.	90
4.5	Resultados estatísticos da classificação de feições da melhor combinação de bandas espectrais e dos diferentes índices de turbidez indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação dos β	93
4.6	RMSE e MAE obtidos para valores de turbidez após calibração do índice NLTDI usando dois pontos de medição <i>in situ</i> . A campanha de 28/10/2021 foi excluída pois não foram feitas mensurações próximas aos pontos adotados (montante/jusante).	96
4.7	Performance da avaliação das feições individuais para SDD.	100
4.8	Matriz de correlação para SDD.	101
4.9	Resultado da seleção de variáveis por <i>ranking</i> via <i>Knock-out</i> para SDD.	103

4.10	Resultados estatísticos da classificação de feições das melhores bandas espectrais e dos diferentes índices de SDD indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação dos β	104
4.11	RMSE e MAE obtidos para valores de SDD após calibração dos modelos SDD_2 e SDD_5 , respectivamente, usando dois pontos de medição <i>in situ</i> . A campanha de 28/10/2021 foi excluída pois não foram feitas mensurações próximas aos pontos adotados (montante/jusante).	110
4.12	Performance da avaliação das feições individuais para chl-a.	112
4.13	Matriz de correlação para chl-a.	115
4.14	Resultado da seleção de variáveis por <i>ranking</i> via <i>Knock-out</i> para chl-a.	117
4.15	Resultados estatísticos entre as medidas de chl-a e os índices de chl-a indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação dos β	120
4.16	RMSE e MAE obtidos para valores de chl-a após calibração do índice $Chla_5$ usando dois pontos de medição <i>in situ</i>	120
4.17	Comparação entre aplicação da regressão linear e calibração em dois pontos no Reservatório Várzea das Flores.	126
1	Síntese das abordagens utilizadas entre os anos de 2000 e 2020 para sensoriamento remoto da qualidade de águas continentais.	150
2	Valores obtidos dos parâmetros opticamente ativos avaliados em Julho/2019 por Curtarelli (2020).	158
3	Valores obtidos dos parâmetros opticamente ativos avaliados em Outubro/2019.	158
4	Valores obtidos dos parâmetros NOA avaliados em Outubro/2019.	159
5	Valores obtidos dos parâmetros opticamente ativos avaliados em Maio/2020.	159
6	Valores obtidos dos parâmetros opticamente ativos avaliados em Maio/2021.	160
7	Valores obtidos dos parâmetros opticamente ativos avaliados em Junho/2021.	161
8	Valores obtidos dos parâmetros opticamente ativos avaliados em Agosto/2021.	162
9	Valores obtidos dos parâmetros opticamente ativos avaliados em Setembro/2021.	163
10	Valores obtidos dos parâmetros opticamente ativos avaliados em Outubro/2021.	164

Lista de Siglas e Símbolos

SIGLAS

- AHS: Airborne Hyperspectral Scanner
- ANA: Agência Nacional das Águas
- ANEEL: Agência Nacional de Energia Elétrica
- AOP: Apparent Optical Properties
- AVHRR: Advanced Very High Resolution Radiometer
- BOA: Bottom-of-Atmosphere
- CDOM: Colored Dissolved Organic Matter
- CEMIG: Companhia Energética de Minas Gerais
- CERH: Conselho Estadual de Recursos Hídricos
- CNES: Centre National d'Études Spatiales
- COA: Componente Opticamente Ativo
- CODEVASF: Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba
- CONAMA: Conselho Nacional de Meio Ambiente
- COPAM: Conselho Estadual de Política Ambiental
- CZCS: Coastal Zone Color Scanner
- ESA: European Space Agency
- ETM+: Enhanced Thematic Mapper Plus
- FNU: Formazin Nephelometric Units
- GNDVI: Green Normalized Difference Vegetation Index
- GNSS: Global Navigation Satellite System

- GPS: Global Positioning System
- HRV: High Resolution Visible
- IGAM: Instituto Mineiro de Gestão das Águas
- INPE: Instituto Nacional de Pesquisas Espaciais
- IOP: Inherent Optical Properties
- ICE: Índice de Conformidade ao Enquadramento
- IET: Índice de Estado Trófico
- IQA: Índice de Qualidade de Água
- MAE: Mean Absolute Error
- MERIS: MEdium Resolution Imaging Spectrometer
- MODIS: Moderate-Resolution Imaging Spectroradiometer
- MSI: Multi-Spectral Imagers
- MSS: Multi-Spectral Scanner
- MWR: Microwave Radiometer
- NASA: National Aeronautics and Space Administration
- NDWI: Normalized Difference Water Index
- NDVI: Normalized Difference Vegetation Index
- NIR: Near Infrared
- NOA: Non-optically Active Parameters
- NOAA: National Oceanic and Atmospheric Administration
- NRMSE: Normalized Root Mean Square Error
- OLCI: Ocean and Land Color Instrument
- OLI: Operational Land Image
- OTB: Orfeu ToolBox
- PEPS: Plateforme d'Exploitation des Produits Sentinel
- PNRH: Política Nacional de Recursos Hídricos
- RADAR: Radio Detection and Ranging

- RMSE: Root Mean Square Error
- RNA: Redes Neurais Artificiais
- SAR: Synthetic Aperture Radar
- SDD: Secchi Disk Depth
- SEMAD: Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável
- SIG: Sistema de Informações Geográficas
- SISEMA: Sistema Estadual de Meio Ambiente
- SLSTR: Sea and Land Surface Temperature Radiometer
- SNAP: Sentinel Application Platform
- SPOT: Satellite Pour l'Observation de la Terre
- SWIR: Shortwave Infrared
- TM: Thematic Mapper
- TOA: Top-of-Atmosphere
- TSM: Total Suspended Matter
- UFMG: Universidade Federal de Minas Gerais
- UHE: Usina Hidrelétrica
- USGS: United States Geological Survey
- NTU: Nephelometric Turbidity Unit
- VANT: Veículo Aéreo Não Tripulado
- VHR: Very High Resolution

SÍMBOLOS

- r^2 : Coeficiente de determinação
- λ : Comprimento de onda
- β : Coeficiente de regressão
- μ : Micrograma
- ρ : Reflectância aparente no topo da atmosfera

Sumário

1 INTRODUÇÃO	17
2 REVISÃO BIBLIOGRÁFICA	20
2.1 Qualidade da água	20
2.1.1 Parâmetros de qualidade de água	21
2.1.2 Legislação ambiental	22
2.2 Sensoriamento remoto de águas continentais	23
2.2.1 Princípios físicos	26
2.2.2 Instrumentos usados no sensoriamento remoto aquático	29
2.2.3 Monitoramento ambiental remoto de parâmetros ópticos em reservatórios	34
2.2.4 Modelagem dos parâmetros ópticos	35
2.2.5 Aplicações recentes das metodologias utilizadas em sensoriamento remoto e qualidade da água	48
2.3 Modelagem matemática e análise estatística aplicada aos parâmetros ópticos	49
2.3.1 Modelagem matemática da qualidade de águas superficiais no contexto do sensoriamento remoto de águas continentais	49
2.3.2 Calibração e validação de modelos ópticos	55
2.3.3 Limitações dos modelos de qualidade da água por técnicas de sensoriamento remoto	56
3 MATERIAIS E MÉTODOS	58
3.1 Área de estudo	59
3.1.1 O Reservatório de Três Marias	59
3.2 Aquisição dos dados limnológicos e de sensoriamento remoto	62
3.2.1 Planejamento amostral	62
3.2.2 Aquisição dos dados limnológicos	62
3.2.3 Aquisição dos dados de sensoriamento remoto	66
3.3 Processamento dos dados	67
3.3.1 Processamento dos dados limnológicos	67
3.3.2 Processamento dos dados de sensoriamento remoto	67
3.4 Modelagem estatística dos parâmetros de qualidade da água	68
3.4.1 Modelos ópticos de estimativa dos parâmetros	68

3.4.2 Modelos de regressão	69
3.4.3 Validação dos modelos e avaliação da acurácia	74
4 RESULTADOS E DISCUSSÃO	75
4.1 Qualidade da água do Reservatório de Três Marias	75
4.2 Modelagem óptica dos parâmetros	80
4.2.1 Turbidez	80
4.2.2 Profundidade do Disco de Secchi	95
4.2.3 Concentração de chl-a	109
4.3 Análise da dinâmica espacial da turbidez, transparência e chl-a no Reservatório de Três Marias	120
4.4 Replicação da abordagem proposta: Reservatório Várzea das Flores	124
5 CONSIDERAÇÕES FINAIS	128
5.1 Sugestões para trabalhos futuros	129
REFERÊNCIAS	148
APÊNDICES	149
ANEXOS	165

Capítulo 1

INTRODUÇÃO

A ÁGUA é um recurso natural indispensável, sendo o constituinte inorgânico de maior presença na matéria viva. Ela compõe mais de 60% do peso humano e pode atingir até 98% da matéria de determinados animais aquáticos ([Von Sperling, 2007b](#)). Na produção agrícola mundial, cerca de 40% utiliza o processo de irrigação. Apesar disso, mais de um bilhão de pessoas no mundo não tem acesso à água potável ([Blanchon, 2009](#)).

Com a expansão do uso dos recursos hídricos, aumenta a necessidade de avaliar a qualidade da água para garantir sua adequada utilização. O monitoramento dos parâmetros de qualidade da água demanda custos altos relacionados às coletas e à análise de amostras coletadas ([Karaoui et al., 2019](#); [Yepez et al., 2018](#)), além dos custos referentes ao tempo despendido neste processo e à mão-de-obra especializada ([Giardino et al., 2010](#)).

O monitoramento da qualidade da água em ambientes lênticos é uma das exigências para a gestão eficiente dos recursos hídricos, uma vez que por meio dele é possível garantir a sua sustentabilidade além de analisar a dinâmica do ambiente ao considerar as atividades antrópicas do entorno ([Odermatt et al., 2008](#)). A qualidade da água destes ambientes pode ser determinada em seus aspectos físicos, químicos e/ou biológicos. Quando caracterizados os componentes, diversos parâmetros ou indicadores podem ser quantificados de forma a atestar a qualidade da água e estabelecer as condições de uso. Os grandes reservatórios brasileiros demandam o monitoramento extensivo de um elevado número de parâmetros ambientais, que atualmente são realizados de forma tradicional e *in situ*, o que pode dificultar ações de preservação e de controle ambiental em tempo satisfatório.

O monitoramento realizado de forma remota é uma alternativa que possibilita a estimativa de alguns parâmetros de qualidade da água com alta frequência temporal, uma vez que diversos satélites apresentam aquisição sistemática de imagens e dados pontuais georreferenciados com resoluções variando de centímetros a quilômetros. Dentre os satélites mais comuns pode-se citar as missões das séries Landsat, Sentinel, MODIS, SPOT e Proba-V. Eles fornecem imagens com uma frequência temporal permitindo aquisição de dados bimestralmente (Landsat) a diariamente (MODIS, Sentinel-3).

A modelagem matemática e a evolução dos recursos computacionais têm auxiliado na aplicabilidade de modelos e algoritmos em estudos de sistemas ambientais dinâmicos ([Pereira, 2016](#)). O uso do

algoritmo para avaliação da qualidade da água de reservatórios possibilita trabalhar com um grande número de imagens e diversas séries temporais. A modelagem espacial e estatística são ferramentas eficazes em relação à geração de modelos distribuídos de alguns parâmetros de qualidade da água. Com o uso do sensoriamento remoto, as técnicas de modelagem geoespacial em ambiente de sistema de informação geográfica (SIG) possibilitam a geração de indicadores valiosos, tanto para o monitoramento da qualidade da água quanto para as mudanças ocorridas no entorno do corpo hídrico. Neste contexto, um sistema automatizado no processamento das imagens pode possibilitar uma redução significativa de tempo e de erros, bem como garantir uma padronização de tratamento das imagens utilizadas (Pinto *et al.*, 2014).

Existem centenas de parâmetros que podem indicar a qualidade da água. Entretanto, os indicadores mais comumente usados em conjunto com técnicas de sensoriamento remoto são clorofila-a (chl-a), transparência, turbidez e total de material suspenso (TSM) (Avdan *et al.*, 2019). Estas técnicas permitem quantificar, além destes, outros parâmetros importantes para a detecção da qualidade da água, como matéria orgânica dissolvida colorida (CDOM), ficocianina (PC), cor verdadeira e temperatura. Ainda é possível inferir indiretamente outros indicadores não-opticamente ativos como fósforo total (TP) (Xiong *et al.*, 2019), nitrogênio total (TN) (Liu *et al.*, 2015), pH, demanda química de oxigênio (COD) e oxigênio dissolvido (DO) (Wang *et al.*, 2012; 2014; Pu *et al.*, 2019).

O sensoriamento remoto aplicado à qualidade da água com enfoque em pesquisa científica vem sendo abordado em várias áreas do conhecimento além da hidrologia, como hidrobiologia (Zhang *et al.*, 2016; Bresciani *et al.*, 2018), saúde pública (Torbick *et al.*, 2014; Van der Merwe e Price, 2015; Torbick *et al.*, 2018), planejamento urbano (Huo *et al.*, 2014; Liu *et al.*, 2015), estatística aplicada (Wilkie *et al.*, 2019; Li *et al.*, 2020), entre outras áreas.

Independentemente da finalidade da aplicação, diversos autores relatam a importância do avanço das pesquisas sobre o monitoramento remoto dos parâmetros de qualidade da água como forma de facilitar a aquisição dos dados (Bonansea *et al.*, 2015; Abdelmalik, 2018; Avdan *et al.*, 2019). Esta abordagem pode ajudar a resolver problemas de monitoramento com um número insuficiente de amostras e baixa periodicidade de coleta resultando em um entendimento escasso dos padrões espaciais do corpo d'água (Wilkie *et al.*, 2019). O sensoriamento remoto permite a compreensão do contexto espaço-temporal indispensável para o gerenciamento, público ou privado, do recurso hídrico (Stefouli e Charou, 2012).

Estes aspectos representam vantagens valiosas da ferramenta que tem sido amplamente empregada em estudos voltados para o monitoramento de lagos e reservatórios. Os ambientes lênticos sofrem constantes ameaças que se caracterizam, principalmente, pelas alterações no nível da água, poluição tóxica, salinização, eutrofização, acidificação, poluição de sedimentos e invasão de espécies exóticas, que podem contribuir para a deterioração das águas (Odermatt *et al.*, 2018).

No entanto, grande parte dos estudos atuais utilizam dados de ambientes aquáticos demasia-damente eutrofizados ou com alto índice de turbidez, o que comprova que a qualificação de águas claras por sensoriamento remoto seja um desafio. As águas do Reservatório de Três Marias, localizado na Sub-bacia do Alto São Francisco e alvo deste estudo, apresentam características que podem variar de águas claras a moderadamente claras. Há uma grande importância no monitoramento da qualidade

da água da represa em questão, uma vez que ela está inserida em um local estratégico do ponto de vista territorial. Ali se insere a Usina Hidrelétrica de Três Marias, sob a concessão da Companhia Energética de Minas Gerais (CEMIG). O reservatório exerce papel fundamental para a população devido à geração de energia, abastecimento de água, lazer, transporte, entre outros múltiplos usos.

Neste contexto, a hipótese que origina o trabalho parte da premissa de que os avanços alcançados pelo sensor MSI presente nos satélites Sentinel-2 aprimora a estimativa dos parâmetros opticamente ativos em águas relativamente claras. O principal objetivo deste trabalho consiste em desenvolver um algoritmo empírico capaz de estimar os parâmetros ópticos da água no Reservatório de Três Marias de forma a permitir sua avaliação de maneira sistemática por meio de técnicas de sensoriamento remoto.

Para alcançar o objetivo principal foram formulados os seguintes objetivos específicos:

1. Investigar a relação entre a concentração dos componentes opticamente ativos (COA) e a reflectância espectral (ρ) da água a partir de dados medidos *in situ* e imagens ópticas obtidas pelo satélite multiespectral Sentinel-2/MSI;
2. Avaliar a modelagem da qualidade da água por meio do uso de algoritmos empíricos aliados à técnicas estatísticas a partir dos dados referentes aos parâmetros ópticos no Reservatório de Três Marias;
3. Analisar por meio dos modelos obtidos a dinâmica espacial da concentração de chl-a, transparência e turbidez da água do reservatório;
4. Discutir o resultado dos modelos avaliando a acurácia do sensor MSI para a estimativa dos parâmetros trabalhados.

É fundamental ressaltar que os modelos não substituem as observações de campo e, tampouco, as análises laboratoriais; entretanto, o uso da modelagem computacional proporciona o aumento da eficiência na estimativa dos parâmetros (Christofolletti, 1999).

O trabalho é dividido em cinco capítulos. Após a introdução, o Capítulo 2 aborda os principais aspectos acerca da qualidade da água e do monitoramento remoto em lagos e reservatórios. É apresentada a revisão da literatura sobre os principais temas abordados nesta pesquisa, os avanços alcançados até os dias atuais e as limitações existentes. No Capítulo 3, temos a apresentação da área de estudo e as etapas metodológicas necessárias para o desenvolvimento da pesquisa. O Capítulo 4 apresenta e discute os resultados encontrados. Por fim, o Capítulo 5 apresenta as considerações finais da pesquisa e sugestões para trabalhos futuros.

Esta tese é produto de um Projeto de Pesquisa e Desenvolvimento (P&D GT-607 CEMIG/ANEEL) e foi concebida no contexto do projeto intitulado “Monitoramento inteligente da qualidade da água em reservatórios hidrelétricos através do desenvolvimento de um algoritmo fotogramétrico”.

Capítulo 2

REVISÃO BIBLIOGRÁFICA

2.1 Qualidade da água

A ÁGUA é responsável pela cobertura de aproximadamente 70% da superfície terrestre. Parte integrante da biosfera, os ambientes aquáticos podem ser classificados como ambientes de água salgada, doce ou salobra e podem ser subdivididos em lóticos ou lênticos (Benedetti e Sforzi, 1999). Os reservatórios estão situados em uma posição intermediária entre os ambientes lóticos e lênticos (também chamados de semi-lênticos) e, de acordo com a dinâmica específica de cada um, podem ser considerados ambientes semi-fluviais com ecossistemas aquáticos contínuos (Kimmel e Groeger, 1984). O fluxo constante de água de montante a jusante permite classificar os reservatórios em zonas lóticas, de transição e lênticas (Moura Júnior *et al.*, 2011).

A técnica de represamento é utilizada de forma a satisfazer objetivos como a geração de energia elétrica, lazer, irrigação, piscicultura, navegação, abastecimento humano e industrial, regularização de água e turismo. Estes múltiplos usos se traduzem como importantes benefícios que atendem às necessidades de vários grupos e atores. Em função dos diversos usos, preservar a qualidade da água dos reservatórios representa um desafio frente ao gerenciamento e gestão destes ambientes. A construção de represas pode ocasionar alterações não só benéficas mas também prejudiciais aos ambientes aquático e terrestre (Esteves, 1998). Os impactos podem ser representados por mudanças dos fluxos fluviais, pelo aumento ou diminuição da contribuição para aquíferos subterrâneos, por alterações na evaporação, balanço hídrico, frequência de cheias e secas além das potenciais mudanças na quantidade e qualidade da água (Christofolletti, 1999). Além disso, os reservatórios hidrelétricos são capazes de emitir gases de efeito estufa caso possuam níveis elevados de eutrofização (Watanabe *et al.*, 2015).

A poluição dos corpos hídricos acarreta a degradação da qualidade da água e implica na deterioração do ambiente aquático como todo. A alteração da qualidade do recurso pode contribuir para o agravamento de problemas específicos relacionados à quantidade de água, como a possibilidade de escassez devido à contaminação de mananciais (Braga *et al.*, 2005). Uma forma eficiente de controle da qualidade da água demanda o monitoramento frequente dos parâmetros identificados no ambiente aquático.

De acordo com [Von Sperling \(2007a\)](#), pode-se elencar duas condições que afetam a qualidade da água: fenômenos naturais (por meio do escoamento superficial e infiltração de água no solo) e a interferência da atuação humana (o uso e a ocupação do solo). Estes fatores que ocasionam impactos negativos à qualidade da água exigem a prática de ações mitigadoras a fim de garantir sua preservação, o que inclui a necessidade de controle da qualidade da água bem como da compreensão do uso e ocupação do solo no entorno destes reservatórios ([Silva et al., 2009](#)).

2.1.1 Parâmetros de qualidade de água

Água pura indica a inexistência de quaisquer constituintes presentes na água. Entretanto, a água exerce a função de um solvente altamente potente, o que dificulta encontrá-la pura na natureza ([Braga et al., 2005](#)). A contaminação existente na água, nos diferentes estágios, se manifesta como impurezas que podem corresponder a diversas fontes, seja ela por meio dos efluentes lançados provenientes de atividades antrópicas, seja de maneira natural pelo carreamento de materiais provenientes das ações dos ventos, chuvas, etc.

Quando o uso do recurso hídrico é destinado para o abastecimento humano ou para recreação de contato primário, por exemplo, torna-se necessário o controle e diagnóstico da qualidade da água, uma vez que é possível que uma água de má qualidade provoque a difusão de doenças causadas por micro-organismos ([Oliveira, 2017](#)). Além de toda a problemática envolvida quando se trata do consumo humano, um reservatório composto por água de qualidade comprometida significa também um ambiente com ecossistema aquático deteriorado ([Campos e Leite, 2019](#)).

Para avaliar a qualidade de um determinado reservatório é necessário realizar um processo de amostragem por meio de coletas pontuais ao longo do corpo d'água. Estas medições permitirão identificar seus componentes, sua concentração e a situação do meio em que a água se encontra ([Barbosa et al., 2019](#)). A avaliação destes parâmetros pode ser realizada em laboratório por meio de análises químicas ou *in situ* com o auxílio de sondas e/ou sensores.

A qualidade da água de ambientes lênticos pode ser determinada pelos seus aspectos físicos, químicos e/ou biológicos. Uma vez conhecida a condição deste ambiente e a relação entre estas variáveis, diversos parâmetros ou indicadores podem ser quantificados de forma a atestar a qualidade da água. Por meio destes parâmetros é possível estabelecer as condições do recurso para seu uso e consumo.

[Von Sperling \(2007a\)](#) classifica os constituintes presentes na água de acordo com as suas características (Figura 2.1). Estes componentes, que alteram o estado de pureza da água, podem apresentar características físicas encontradas no estado sólido (série de sólidos, resíduos) ou gasoso (dissolvidos), características químicas que podem ser de ordem inorgânica (como sais e metais) ou orgânica (matérias em decomposição) e/ou características biológicas que estão representadas pelos seres vivos de origem animal, vegetal ou protistas.

Existe uma série de parâmetros que permitem classificar a qualidade da água. Mensurar todos os parâmetros de qualidade da água, além de ser uma tarefa extremamente difícil e custosa e pode ser desnecessária. Os parâmetros a ser selecionados dependem do tipo de uso para o qual está destinado o reservatório e do contexto do entorno ao corpo d'água, considerando os potenciais focos de

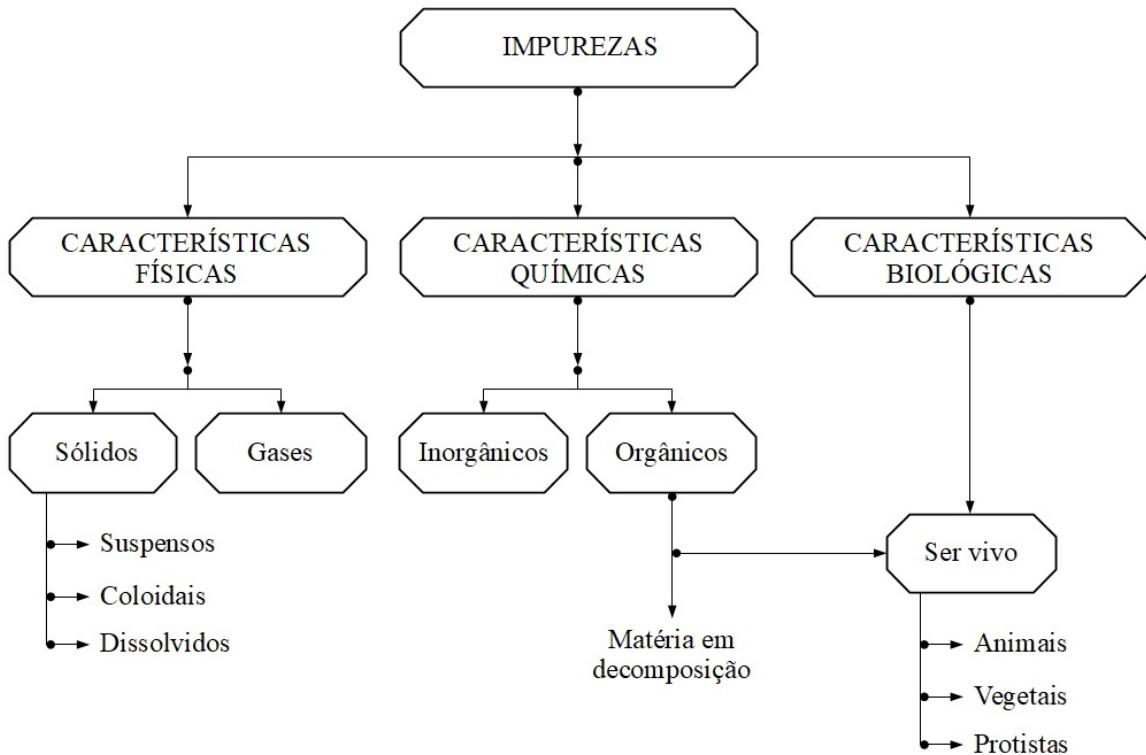


Figura 2.1: Impurezas contidas na água.

Fonte: [Von Sperling \(2007a\)](#).

contaminação ([Santos et al., 2001](#)).

[Barbosa et al. \(2019\)](#) elencaram as variáveis que podem ser monitoradas por meio de técnicas de sensoriamento remoto resultando, consequentemente, na redução do custo das análises. São elas: concentração de chl-a, de ciano-ficocianina e ciano-ficoeritrina, absorção pela matéria orgânica dissolvida colorida, concentração do total de material em suspensão, atenuação difusa (vertical) da luz na água, transparência da água, turbidez e limite da zona eufótica.

2.1.2 Legislação ambiental

O estabelecimento de um determinado padrão de qualidade da água é relativo uma vez que depende do tipo de uso que será feito. Um padrão de qualidade que atenda ao abastecimento humano nem sempre é o mesmo padrão exigido para ambientes aquáticos destinados a outros fins.

Em 08 de janeiro de 1997 foi instituída a Política Nacional de Recursos Hídricos (PNRH), além da criação do Sistema Nacional de Gerenciamento de Recursos Hídricos por meio da Lei nº 9433 (Lei das Águas). Os principais objetivos da PNRH são ([Brasil, 1997](#)):

1. ASSEGURAR às gerações atuais e futuras a disponibilidade de água de qualidade adequada aos respectivos usos;

2. GARANTIR a utilização racional e integrada dos recursos hídricos tendo em vista o desenvolvimento sustentável e;
3. PREVENIR/DEFENDER os recursos contra eventos hidrológicos críticos de quaisquer origem.

Três anos mais tarde, em 17 de julho de 2000, a Lei de nº 9984 foi editada dispondo da criação da Agência Nacional de Águas e Saneamento Básico (ANA), entidade federal de implementação da PNRH e de coordenação do Sistema Nacional de Gerenciamento de Recursos Hídricos. Entre outras atribuições, cabe à ANA fiscalizar os usos de recursos hídricos de domínio federal bem como as condições de operação dos reservatórios por agentes públicos e privados de forma a garantir o uso múltiplo dos recursos ([Brasil, 2000](#)).

Os corpos hídricos são enquadrados em classes de acordo com seu uso e, para cada classe de enquadramento, a legislação prevê valores máximos de concentração de constituintes que definirão seu padrão de qualidade ([Braga et al., 2005](#)). Foram instituídos, por meio da Resolução nº 357, de 17 de março de 2005 do Conselho Nacional de Meio Ambiente (CONAMA), as condições e padrões de qualidade da água, além da sua classificação de acordo com a qualidade necessária para os múltiplos usos.

A Resolução CONAMA 357/2005 distingue os corpos d'água de acordo com o teor de salinidade e os classifica como águas doces (salinidade igual ou inferior a 0,5%), águas salobras (salinidade superior a 0,5% e inferior a 30%) e águas salinas (superior a 30%) ([Brasil, 2005](#)). O Reservatório de Três Marias é totalmente composto por águas doces. As águas doces podem ser categorizadas em cinco classes diferentes, de acordo com a indicação da Tabela 2.1.

No âmbito do Estado, o Conselho Estadual de Política Ambiental (COPAM) em conjunto com o Conselho Estadual de Recursos Hídricos do Estado de Minas Gerais (CERH-MG) determinaram por meio da Deliberação Normativa Conjunta nº 01, de 05 de maio de 2008, a classificação e diretrizes ambientais para o enquadramento dos corpos d'água superficiais, condições e padrões de lançamento de efluentes ([Minas Gerais, 2008](#)). A criação desta Deliberação teve o intuito, entre outras finalidades, de restringir os propósitos da Resolução CONAMA 357/2005 de acordo com as peculiaridades dos corpos hídricos do Estado de Minas Gerais. Esta Deliberação possibilitou o enquadramento dos recursos hídricos em classes sendo esta ação competência das Agências de Bacia Hidrográfica ou Entidades equiparadas ([IGAM, 2020](#)).

2.2 Sensoriamento remoto de águas continentais

O uso de diferentes técnicas de sensoriamento remoto aplicadas aos recursos hídricos tem sido explorado no mundo desde a década de 1960, quando dados digitais de imagens adquiridas a bordo de satélites tornaram-se disponíveis ([Mertes et al., 2004](#)). Desde então, os sensores têm sido utilizados para determinar a quantidade e/ou a qualidade da água.

A aferição das medições dos níveis de água dos ambientes lóticos e lênticos *in situ* é feita por meio de estações de medição instaladas nos corpos d'água. Entretanto, estes instrumentos geralmente são únicos e restritos apenas a canais de grande porte ([Alsdorf et al., 2000](#)). No sentido de aprimorar

Tabela 2.1: Classificação dos corpos de águas doces.

Classe	Destinação
Especial	a) Abastecimento para consumo humano com desinfecção; b) Preservação do equilíbrio natural das comunidades aquáticas; c) Preservação dos ambientes aquáticos em unidades de conservação de proteção integral.
Classe 1	a) Abastecimento para consumo humano, após tratamento simplificado; b) Proteção das comunidades aquáticas; c) Recreação de contato primário, tais como natação, esqui aquático e mergulho, conforme Resolução CONAMA 274/2000; d) Irrigação de hortaliças que são consumidas cruas e de frutas que se desenvolvam rentes ao solo e que sejam ingeridas cruas sem remoção de película; e) Proteção das comunidades aquáticas em Terras Indígenas.
Classe 2	a) Abastecimento para consumo humano, após tratamento convencional; b) Proteção das comunidades aquáticas; c) Recreação de contato primário, tais como natação, esqui aquático e mergulho, conforme Resolução CONAMA 274/2000; d) Irrigação de hortaliças, plantas frutíferas e de parques, jardins, campos de esporte e lazer, com os quais o público possa vir a ter contato direto; e) Aquicultura e atividade de pesca.
Classe 3	a) Abastecimento para consumo humano, após tratamento convencional ou avançado; b) Irrigação de culturas arbóreas, cerealíferas e forrageiras; c) Pesca amadora; d) Recreação de contato secundário; e) Dessedentação de animais.
Classe 4	a) Navegação; b) Harmonia paisagística.

Fonte: [Brasil \(2005\)](#).

e auxiliar as medições quantitativas da água em lagos e reservatórios, o sensoriamento remoto por interferometria de radar tradicionalmente tem sido utilizado de maneira a relacionar o nível e o volume d'água do ambiente ([Alsdorf e Lettenmaier, 2003](#)). Para estimar a quantidade de água utilizando missões altimétricas é necessário calcular os níveis de água por meio de longas séries temporais ([Cretaux *et al.*, 2018](#)). O avanço tecnológico, o lançamento de novas missões e a facilidade na aquisição dos dados digitais contribuíram para o aumento de estudos envolvendo quantidade de água e altimetria. A Figura 2.2 apresenta o histórico das missões altimétricas e a previsão de novos lançamentos no século XXI.

Com relação às características qualitativas do recurso hídrico, a procura pelo uso de técnicas de sensoriamento remoto para determinação da qualidade da água se deu, inicialmente, pela suposição de que a chl-a e a temperatura da superfície aquática pudessem ser estimadas remotamente, o que motivou pesquisadores a estudar as propriedades ópticas presentes nos constituintes da água para mensurar estes e de outros parâmetros que indicam o estado e a qualidade da água ([Mishra *et al.*,](#)

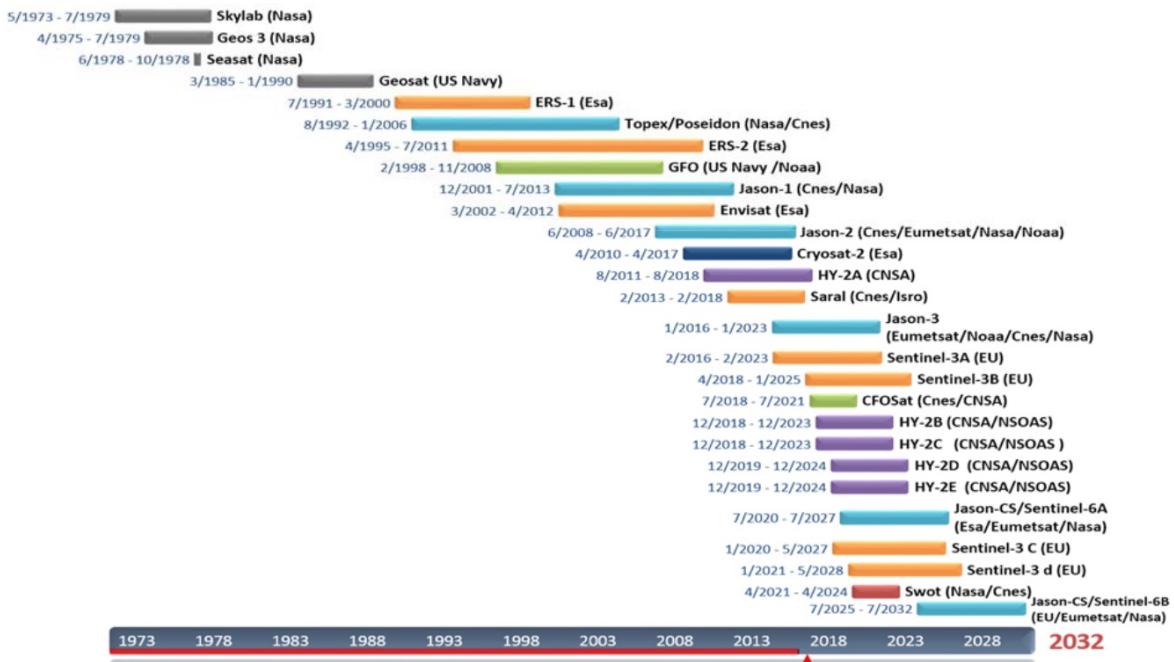


Figura 2.2: Histórico e previsão de lançamento de missões altimétricas.

Fonte: [AVISO \(2020\)](#).

[2017](#)).

O satélite Nimbus-7, lançado em 1978 pela NASA (*National Aeronautics and Space Administration*) com o sensor *Coastal Zone Color Scanner* (CZCS), foi o primeiro satélite dedicado aos recursos hídricos. Seu instrumento operou até 1995 e, por meio deste, tornou-se possível obter dados sobre a cor (cinco bandas espectrais entre 443 e 750 nm) e a temperatura dos oceanos ([Shapiro, 2004](#)). Atualmente, vários sensores, dedicados ou não, são utilizados para estudos que contemplam os corpos d'água. Entretanto, seu uso para monitorar a qualidade da água somente foi amplamente difundido a partir da associação do uso de algoritmos bio-ópticos envolvendo sensores hiper e multiespectrais ([Ogashawara et al., 2016](#)).

Em vista às inovações tecnológicas envolvendo os sensores orbitais, é possível afirmar ainda que há uma ampla perspectiva de estudos em sistemas aquáticos. De acordo com [Mertes et al. \(2004\)](#), na década de 1980 houve entre 20 e 30 publicações relacionando águas interiores e cobertura do solo à aplicação de técnicas de sensoriamento remoto e um aumento que variou entre 30 e 40 publicações na década de 1990 sob o mesmo viés. De acordo com os autores, este aumento ocorreu devido à relevância e confiabilidade destes dados que podem ser empregados em diversas áreas interessantes à sociedade, tais como em meio ambiente, saúde e lazer, entre outras.

No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) realizou diversos estudos científicos aplicados à água com dados de sensoriamento remoto. O primeiro trabalho acadêmico em nível de pós-graduação *stricto sensu* do órgão utilizando técnicas de sensoriamento remoto em sistemas aquáticos foi desempenhado pela pesquisadora Tânia Sausen em 1980, onde a autora investigou

o aumento da turbidez no Reservatório de Três Marias/MG ([Barbosa et al., 2019](#)).

2.2.1 Princípios físicos

A interação entre a radiação eletromagnética e a matéria forma a base para as estimativas da qualidade dos ambientes aquáticos com sensoriamento remoto. Dentre os instrumentos utilizados por meio desta técnica estão os radares de micro-ondas, instrumentos a laser (Lidars) e os espectrômetros passivos que operam na região óptica e térmica do espectro eletromagnético; sendo estes últimos os mais utilizados para o monitoramento aquático ([Koponen, 2006](#)). Os sensores passivos aplicados aos estudos de água medem a radiância que, posteriormente, pode ser transformada em refletância da superfície aquática. A resposta do sensor, fruto da interação entre a luz e o corpo d'água, é dada de acordo com os constituintes presentes na água.

Um sensor aerotransportado ou a bordo de satélite é capaz de captar a radiância total (L_t) emitida que é função da energia eletromagnética (Figura 2.3) produto de:

- parte da radiância da radiação solar direta (E_{Sun}) e indireta (E_{Sky}) descendente: não atingindo a superfície aquática (L_p);
- radiância da radiação solar e atmosférica descendente na interface ar-água: penetração de aproximadamente 1 mm na água e refletida da superfície aquática (L_s);
- radiância da radiação solar e atmosférica descendente que penetra na interface ar-água e interage com os componentes aquáticos emergindo da coluna d'água: não há interação com o fundo do corpo hídrico (L_v);
- parte da radiância da radiação solar direta e indireta descendente que penetra, atinge o fundo do corpo hídrico e fornece resposta ao sensor por meio da propagação de retorno da coluna d'água (L_b).

Os diferentes sensores captam por meio de imagens os efeitos da relação entre a radiação solar refletida (nos processos de absorção e espalhamento) e os componentes presentes na água, além de fornecer informações espetrais que servem como subsídio para quantificar determinados parâmetros de qualidade da água ([Barbosa et al., 2019](#)) e quantidade, em alguns casos. [Mertes et al. \(2004\)](#) apontam o uso de sensores como Landsat-TM, SPOT HRV, CZCS e NOAA-AVHRR no sensoriamento remoto aplicado às águas e citam as características adequadas dos detectores ópticos para estimar a qualidade da água, como tempo de voo, cobertura, influência atmosférica, condições climáticas, entre outras variáveis.

Assim como em ambientes terrestres, a reflectância e absorção dos COA da água podem ser estudados em determinados comprimentos de onda. Os sensores atuam principalmente na parte chamada de óptica do espectro eletromagnético que cobre os comprimentos de onda entre, aproximadamente, 400 nm a 2500 nm. Apenas os sensores infravermelhos termais (*Thermal Infrared – TIR*) cobrem a faixa de 8000 – 12000 nm e podem ser usados para estimar a temperatura da superfície

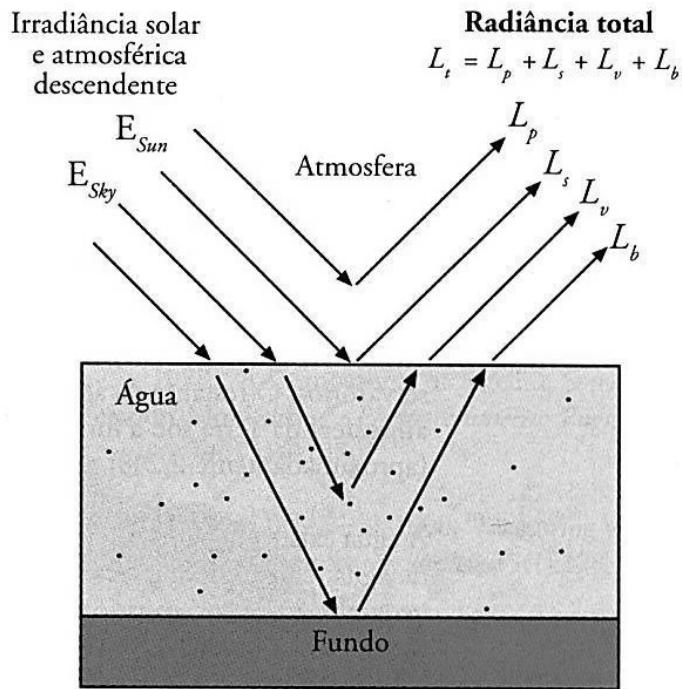


Figura 2.3: Representação da radiância total captada pelo sensor em um corpo d'água.

Fonte: [Jensen \(2009\)](#).

aquática. A faixa de variação entre 3000 – 8000 nm é geralmente usada para determinar a temperatura de nuvens. Os comprimentos mais longos (1 mm – 1 m) correspondem às micro-ondas e são utilizados para sensores do tipo radar ou micro-ondas passivas e não podem ser usados para monitorar a qualidade da água, mas apenas a quantidade medindo a área ou largura de corpos hídricos ou, ainda, o nível (por meio de satélites altimétricos).

Quando em contato com a água, os fôtons de luz interagem principalmente com quatro COA que são a água pura, os pigmentos fotossintetizantes presentes no fitoplâncton, os materiais particulados suspensos (*Suspended Particulate Matter* – SPM) e a matéria orgânica dissolvida colorida (*Colored Dissolved Organic Matter* – CDOM). A resposta espectral dos corpos d'água é maior em comprimentos de onda menores que 760 nm e sua absorção ocorre quase que por completo em comprimentos de onda maiores que 800 nm, o que torna a reflectância e transmitância não significativas nestas ondas mais longas ([McCoy, 2005](#)). A Figura 2.4 mostra o comportamento espectral dos COA:

Onde:

Eixo Y direito: absorção representada pelas linhas sólidas;

Eixo Y esquerdo: espalhamento representado pelas linhas tracejadas;

$r(w)$: retroespalhamento da água;

$r^*(fito)$: retroespalhamento específico de fitoplâncton;

$r^*(SPM)$: retroespalhamento específico de SPM;

$a(w)$: absorção da água;

$a^*(fito)$: absorção específica de fitoplâncton;

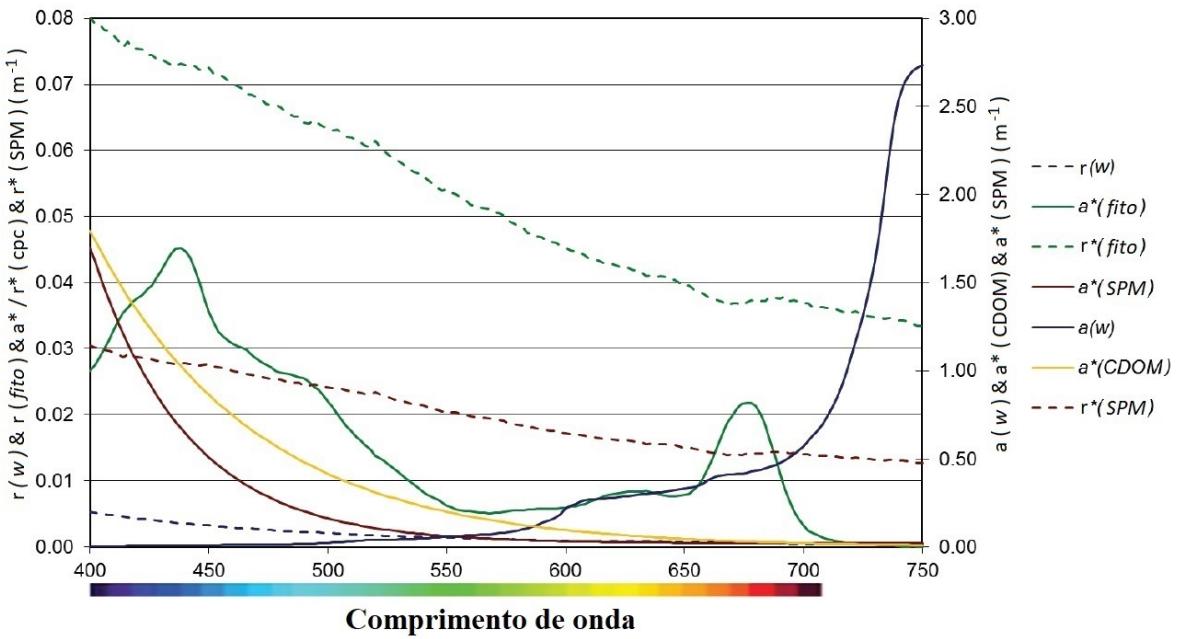


Figura 2.4: Gráfico sobre os espectros de absorção e espalhamento nos comprimentos de onda visíveis para os constituintes bio-ópticos da água.

Fonte: [Harvey \(2015\)](#).

$a^*(SPM)$: absorção específica de SPM;

$a^*(CDOM)$: absorção específica de CDOM.

A interação da luz com estes constituintes permite o retroespalhamento da energia pela superfície aquática para a atmosfera (sofrendo interferências causadas por aerossóis no caminho) até chegar ao sensor. Portanto, os dados refletidos que sofreram interferência devem passar pelo processo de correção atmosférica devido aos seguintes fatores: atmosfera, água pura em razão da absorção e espalhamento, além das propriedades presentes nos COA ([Harvey, 2015](#)).

A água contém uma assinatura espectral única que pode ser distinguida pela alta absorção na faixa do infravermelho próximo (*Near Infrared – NIR*), o que faz com que os corpos d'água possam ser detectados e delimitados facilmente ([Teodoro, 2016](#)). As alterações observadas nas propriedades ópticas da água ocorridas em função de sua resposta espectral provenientes dos efeitos da interação com a radiação solar permite que estes COA sejam usados como indicadores de qualidade da água ([Barbosa et al., 2019](#)).

O meio aquático é composto por dois tipos de propriedades ópticas diferentes. Elas podem ser classificadas como propriedades ópticas inerentes (*Inherent Optical Properties – IOP*) e propriedades ópticas aparentes (*Apparent Optical Properties – AOP*). Estas propriedades são baseadas, principalmente, nas funções de absorção e espalhamento da luz. Os termos foram definidos a fim de distinguir propriedades que independem (IOP) ou não (AOP) da iluminação e das formas dos materiais ([Mishra et al., 2017](#)). Com base no conhecimento das propriedades ópticas da coluna d'água, é possível estimar os valores referentes aos seus parâmetros da qualidade ([Ogashawara et al., 2016](#)).

IOP necessitam apenas da estrutura do meio ambiente, não de sua luz. Embora dependam do meio aquático, estas características independem da distribuição angular da radiância ([Mishra et al., 2017](#); [Mollaee, 2018](#)). As IOP da água são caracterizadas em função de seus coeficientes de:

- a) ABSORÇÃO: energia do fluxo luminoso absorvido por unidade de distância;
- b) ESPALHAMENTO: somatório dos espalhamentos que ocorrem no interior do corpo d'água, considerando todas as direções;
- c) RETROESPALHAMENTO: espalhamento em direção à fonte de radiação eletromagnética;
- d) ATENUAÇÃO TOTAL: somatório dos coeficientes de absorção e espalhamento;
- e) ALBEDO DE ESPALHAMENTO: trata-se de um valor definido pela razão entre o número de interações do espalhamento e o número de interações totais, ou seja, espalhadas e absorvidas ([Mouchot et al., 1996](#)).

As AOP são as propriedades que indicam a cor e a transparência da água de acordo com a sua radiação eletromagnética, dependentes tanto do meio quanto da direção do campo de luz ([Mishra et al., 2017](#); [Barbosa et al., 2019](#)). As AOP são definidas pelas medidas de luminosidade, irradiância, reflectância e atenuação difusa, sendo os coeficientes de reflectância volumétrica e atenuação difusa os mais comumente encontrados na literatura ([Mouchot et al., 1996](#)).

IOP e AOP são conectados por meio de uma equação denominada Equação de Transferência Radiativa, tornando-se a base para o relacionamento entre reflectância e concentração dos COA ([Mollaee, 2018](#)) que serão discutidos a parte nesta pesquisa.

2.2.2 Instrumentos usados no sensoriamento remoto aquático

O sensoriamento remoto aquático permite que sejam feitas observações da superfície da água por meio de séries temporais que possibilitam o fornecimento de dados sobre a dinâmica da qualidade do corpo hídrico ([Zhang et al., 2016](#)). Algumas plataformas e instrumentos de sensoriamento remoto também permitem avaliar a quantidade de água por meio de sensores de altimetria ([Rosmorduc et al., 2006](#)). Os sensores ópticos medem a quantidade de radiação eletromagnética em diferentes comprimentos de onda refletida pela superfície aquática, que geralmente é convertida em brilho ou reflectância ([Alparslan et al., 2009](#)). Em particular, as medidas de reflectância (que são independentes da quantidade de iluminação) são fundamentais para a geração de modelos de sensoriamento remoto aquático ([Li et al., 2020](#)).

Os últimos vinte anos foram marcados pelo desenvolvimento de novos instrumentos (plataformas e sensores) capazes de estimar parâmetros de qualidade da água, alguns especificamente projetados para este fim. Os avanços destas ferramentas incluem resoluções espectrais, espaciais e radiométricas mais finas, menor tempo de revisita, aumento do número de constelações de satélites, além da possibilidade de obtenção gratuita e facilitada de dados. A comunidade científica tem provado a eficácia do uso dos sensores para avaliação de diversos processos incluindo os parâmetros ambientais ([Alparslan](#)

et al., 2010). A estimativa da qualidade da água em ambientes lênticos por sensoriamento remoto pode ser realizada em diferentes escalas, sejam locais, regionais, continentais ou globais (Politi *et al.*, 2015). De acordo com o objetivo da pesquisa, é possível escolher dados de sensores a bordo de satélites ou aerotransportados (Tabela 2.3).

As imagens adquiridas por satélite que cobrem as regiões espectrais do visível e infravermelho apresentam no sinal um brilho referente à reflectância e um brilho correspondente aos efeitos atmosféricos (ruído) que requer processamento para correção, a fim de garantir dados quantitativos precisos (Abdelmalik, 2018). Moléculas na atmosfera e aerossóis absorvem e espalham tanto a radiação solar de entrada quanto a radiação de saída refletida pela superfície da Terra afetando em 90% (no espectro como todo) o sinal que chega ao sensor, um processo geralmente chamado de atenuação atmosférica (Anspel e Alikas, 2019). A maior parte das imagens de satélite de resolução espacial moderada e alta estão disponíveis gratuitamente por meio de agências de satélite como o *Earth Explorer*, do Serviço Geológico dos Estados Unidos (*United States Geological Survey – USGS*), ou o *Copernicus Open Access Hub*, da Agência Espacial Europeia (*European Space Agency – ESA*). É possível também adquirir dados de sensores comerciais de altíssima resolução espacial ou espectral, mas eles podem ser excessivamente caros. Nos casos de modelos que utilizam de dados *in situ* confrontados com os dados de satélite é importante coincidir os dias de campanha e a passagem do satélite para garantir resultados mais precisos evitando o efeito das mudanças nas condições ambientais que alterariam os parâmetros de qualidade da água (Chen *et al.*, 2016).

Muitos sensores multiespectrais e hiperespectrais recentes foram construídos especialmente para uso em plataformas atmosféricas como aviões, helicópteros e veículos aéreos não tripulados (*Unmanned Aerial Vehicle – UAV*), também chamados de drones. O último foi amplamente popularizado nos últimos anos para uso de sensoriamento remoto, principalmente alimentado pela disponibilidade de sensores de peso leve. A escolha da plataforma é ditada principalmente pelo tamanho da área e pela velocidade da plataforma (Van der Merwe e Price, 2015). Vários sensores aerotransportados têm sido usados para sensoriamento remoto de qualidade da água, como o APEX, o MIVIS e o HySpex (Pinardi *et al.*, 2015). Esses equipamentos ainda são relativamente grandes e pesados e só podem ser transportados por aeronaves tripuladas ou drones de última geração. A Tabela 2.2 mostra algumas das principais características desses sensores. As imagens desses sensores permitem uma visão sinótica de corpos d’água de pequeno a médio porte que podem ser monitorados sob diferentes condições climáticas e hídricas com resolução espacial e espectral extremamente alta (Sabat-Tomala *et al.*, 2018). Porém, o alto custo das campanhas programadas de campo pode ser considerado um fator adverso para seu uso.

Os UAVs têm sido considerados uma boa alternativa para os estudos utilizando o sensoriamento remoto aquático, sejam eles do tipo multirotores ou asa fixa. A maioria dos UAVs multirotores tem autonomia de bateria limitada de 30 minutos a algumas horas, dependendo do modelo e da carga útil, mas têm a vantagem de voar em altitudes mais baixas sendo capazes de pairar enquanto a asa fixa pode ser mais eficiente devido à sua maior velocidade podendo cobrir áreas maiores em menos tempo de voo (Van der Merwe e Price, 2015). As câmeras a bordo destes equipamentos podem capturar imagens em altíssima resolução espacial, permitem menor tempo de revisita, acessam áreas difíceis para

Tabela 2.2: Especificações de três sensores hiperespectrais: APEX, MIVIS e HySpex.

Sensor	Faixa espectral	Número de bandas	Resolução espectral	FOV	IFOV	Pixels
APEX	VNIR: 380 – 970 SWIR: 940 – 2500	VNIR: 334 SWIR: 199	VNIR: 0.6 – 6.3 SWIR: 7 – 13.5	28	0.028	1024
MIVIS	I: 430 – 830 II: 1150 – 1550 III: 2.0 – 2.5 VI: 820 – 1270	I: 20 II: 50 III: 8 VI: 450	I: 20 II: 8 III: 64 VI: 10	71.1	0.114	755
HySpex	400 – 800 430 – 820 485 – 960 400 – 1000	72 – 88	5.5	16 – 40	0.016 - 0.039	1024

Tabela 2.3: Sensores de satélites e veículos aerotransportados lançados após os anos 2000, frequentemente usados para avaliação de qualidade da água.

Plataforma / Sensor	Data de lançamento	Bandas espetrais (nm)	Resolução espacial (m)	Resolução temporal (dia)
EO-1/ALI	21/11/2000	6 VNIR (433 – 890); 1 Pan (480 – 690); 3 SWIR (1200 – 2350)	10 – 30	16
EO-1/Hyperion	21/11/2000	242 bandas hiperespectrais: 49 VNIR (426 – 925); 147 SWIR (912 – 2395) 22 bandas sem calibração, sem valores válidos e não incluídas nos ativos do Earth Engine	30	16
NOAA-16/ AVHRR	21/09/2000	2 VNIR (580 – 1110); 1 SWIR (1580 – 1640); 1 MWIR (3550 – 3930); 2 TIR (10300 – 12500)	1100 – 4000	9
DigitalGlobe/ Quickbird	18/10/2001	4 VNIR (430 – 918); 1 Pan (450 – 900)	2.62 -- 0.65	2.5
PROBA-1/ CHRIS	22/10/2001	19 VNIR (400 – 1050)	18 -- 36	7
AHS/CASI- 1500	2002	288 bandas hiperespectrais: VNIR (380 – 1050)	0.25 -- 5	—

ENVISAT/ AATSR	01/03/2002	3 VNIR (555 – 865); 1 SWIR (1600); 1 MWIR (3700); TIR (10850 -- 12000)	1000	3 – 6
ENVISAT/ MERIS	01/03/2002	15 VNIR (390 – 1040)	300 – 1200	3
SPOT-5/HRG	04/05/2002	3 VNIR (500 – 890); 1 Pan (480 – 710); 1 SWIR (1580 – 1750)	2.5 ou 5 – 10 – 20	26
CARTOSAT/ Pan	05/05/2005	1 Pan (500 – 850)	2.5	5
ALOS/ AVNIR-2	24/01/2006	4 VNIR (420 – 890); 1 Pan (520 – 770)	2.5 – 10	2
DigitalGlobe/ WorldView-1	18/09/2007	1 Pan	0.5	1.7
RapidEye/ REIS	29/08/2008	5 VNIR (440 – 850)	5	1 off-nadir 5.5 nadir
HICO/ International Space Station	10/09/2009	128 bandas hiperespectrais: VNIR (350 – 1080)	100	10
DigitalGlobe/ WorldView-2	08/10/2009	8 VNIR (400 – 1040); 1 Pan (450 – 800)	1.85 – 0.46	1.1
COMS/GOCI	26/06/2010	8 VNIR (400 – 865)	500	8 diurnas 2 noturnas
GeoEye/ GeoEye-1	06/09/2010	8 VNIR (450 – 920); 1 Pan (450 – 800)	1.65 – 0.41	< 3
AHS/APEX- ESA	2011	+ 300 bandas hiperespectrais: Padrão: 114 VNIR (380 – 970); 199 SWIR (940 – 2500)	2 – 5	—
Suomi NPP/VIIRS	28/10/2011	5 VNIR (640 – 1145); 16 bandas de resolução mode- rada (412 – 12013); 1 banda dia/noite (500 – 900)	375 – 750	1 – 2 vezes ao dia
AHS/AVIRIS- NG	2012	425 bandas hiperespectrais: (380 – 2510)	0.3 – 4	—
AHS/ AisaFE- NIX	2013	620 bandas hiperespectrais: VNIR (380 – 970); SWIR (970 – 2500)	1 m a 600 m altitude	—

Landsat-8/OLI and TIRS	11/02/2013	5 VNIR (430 – 880); 1 Pan (500 – 680); 2 SWIR (1570 – 2290); 1 banda de detecção de nuvens (1360 – 1380); 2 TIR (10600 – 12510)	30 – 15 – 100	16
AHS/HySpex ODIN-1024	2014	427 bandas hiperespectrais: VNIR (400 – 1000); SWIR (950 – 2500)	0.5 m a 2000 m altitude	—
NOAA/WorldView-3	13/08/2014	8 VNIR (400 – 1040); 1 Pan (450 – 800); 8 SWIR (1195 – 2365)	1.24 – 3.7 – 0.31	1 – 4.5
Sentinel-2A/MSI	23/06/2015	8 VNIR (490 – 865); 2 SWIR (1610 – 2190); 3 bandas de correção atmosférica (443 – 1375)	10 – 20 – 60	10
Sentinel-3A/OLCI	16/02/2016	21 VNIR (400 – 1020)	300 – 1200	< 2.8
DigitalGlobe/WorldView-4	11/11/2016	4 VNIR (655 – 920); 1 Pan (450 – 800)	0.3 – 1.24	1 – 4.5
Sentinel-2B/MSI	07/03/2017	8 VNIR (490 – 865); 2 SWIR (1610 – 2190); 3 bandas de correção atmosférica (443 – 1375)	10 – 20 – 60	10
Sentinel-3B/OLCI	25/04/2018	21 VNIR (400 – 1020)	300 – 1200	< 2.8
PRISMA	Desde 2008. Último sensor lançado em 22/03/2019	238 bandas hiperespectrais: 66 VNIR (400 – 1010); 1 Pan (400 – 700); 171 SWIR (920 – 2505)	5 – 30	29
GEO-KOMPSAT-2B/ GOCCI-II	18/02/2020	1 UV (370 – 390); VNIR (412 – 755); 1 Pan (845 – 885)	250	10 vezes por dia

Fonte: Adaptado de [Gholizadeh et al. \(2016\)](#).

o ser humano, apresentam menor custo que campanhas *in situ* e análises laboratoriais, além de seus produtos não sofrerem com interferências direta das nuvens (sem considerar o sombreamento) ([Kupsinski et al., 2020](#)). Há hoje uma grande variedade de câmeras multiespectrais e hiperespectrais leves

(muitas com menos de 1 kg) especificamente desenvolvidas para os drones economicamente mais acessíveis (especialmente RGB, como Canon ELPH 110HS e Powershot S100). Embora exista no mercado sensores multiespectrais e hiperespectrais que podem ser acoplados a estes equipamentos de alto custo (com valores variados entre US\$ 10.000,00 e US\$ 40.000,00), alguns sensores compactos de baixo custo podem ser adquiridos (Veronez *et al.*, 2018).

2.2.3 Monitoramento ambiental remoto de parâmetros ópticos em reservatórios

O monitoramento da qualidade da água é essencial para garantir um padrão ideal para os seus vários usos. Os grandes reservatórios brasileiros demandam monitoramento extensivo de um elevado número de parâmetros ambientais, uma vez que muitos destes reservatórios fornecem subsídio à população. Para diversos governos ao redor do mundo e setores privados este monitoramento é uma exigência (Harvey, 2015). No âmbito governamental do Brasil este fato ainda não é uma realidade (ANA, 2012).

Em Minas Gerais, o IGAM opera as redes de monitoramento por meio do Programa Águas de Minas, em execução desde 1997. Atualmente, o Instituto registra 620 pontos de monitoramento ativos na Rede Básica dos quais 598 são utilizados para cálculos de IQA e IET (Índice de Estado Trófico). Tais estações estão distribuídas em 17 bacias hidrográficas do Estado que são as bacias dos rios: São Francisco, Grande, Doce, Paranaíba, Paraíba do Sul, Mucuri, Jequitinhonha, Pardo, Buranhém, Itapemirim, Itabapoana, Itanhém, Itaúnas, Jucuruçu, Peruípe, São Mateus e Piracicaba/Jaguarí (IGAM, 2019).

Os programas de monitoramento são de extrema importância para o manejo dos ambientes lênticos. Tratando-se de reservatórios, o ato de construir uma barragem gera a interrupção do transporte de sedimentos, deposição dos sólidos nas represas, alteração do regime hídrico, acúmulo de nutrientes e metilação do mercúrio, podendo afetar o ecossistema aquático (ANA, 2012).

De acordo com Harvey (2015), o monitoramento da qualidade da água remonta a meados do século XIX quando parâmetros como transparência do disco de Secchi e temperatura oceânica já eram mensurados. Ainda hoje, os monitoramentos tendem a ser realizados de forma tradicional *in situ* e podem dificultar as ações de preservação e controle ambiental em tempo satisfatório. Outros fatores também podem ser limitantes neste monitoramento como a dificuldade de se obter dados considerando as particularidades e a dimensão do corpo hídrico em questão (Karaoui *et al.*, 2019).

Embora o sensoriamento remoto permita o relacionamento entre as propriedades ópticas da água e seus constituintes (Veronez *et al.*, 2018; Barbosa *et al.*, 2019), existem parâmetros que não podem ter suas concentrações estimadas diretamente pela tecnologia, uma vez que estes constituintes não apresentam propriedades opticamente ativas. Ainda que estes parâmetros não-opticamente ativos (NOA) possam ser indiretamente inferidos, eles podem representar uma limitação do sensoriamento remoto aquático. A possibilidade de monitoramento remoto de reservatórios está em constante evolução, mas ainda apresenta outras dificuldades no progresso como a projeção dos sensores, efeitos atmosféricos, dinâmica dos corpos d'água e as diferentes barreiras institucionais (Topp *et al.*, 2020).

2.2.4 Modelagem dos parâmetros ópticos

Os métodos de modelagem contribuíram consideravelmente para os estudos hidrológicos fazendo com que a hidrologia se revele como o campo onde a modelagem é mais trabalhada no país (Christofoletti, 1999). O sensoriamento remoto aplicado à qualidade da água com enfoque em pesquisa científica vem sendo abordado em várias áreas do conhecimento. Entretanto, para fazer uso em qualquer pesquisa do sensoriamento remoto aquático é necessário, antes, compreender o comportamento espectral dos componentes da água.

Concentração do Total de Material em Suspensão (*Total Suspended Matter – TSM*)

O sedimento suspenso é considerado um dos indicadores primários na avaliação da qualidade da água (Cui *et al.*, 2013; Chen *et al.*, 2016) e do forçamento físico (ressuspensão provocada pela ação de ventos, escoamento de terra ou operações de dragagem, por exemplo) (Uudeberg *et al.*, 2020) que pode conter diversas substâncias orgânicas e/ou minerais, originárias de variados aspectos do entorno ou ressuspensos diretamente do fundo do lago/reservatório (Soomets *et al.*, 2020). A presença de sedimentos pode provocar impactos, como o assoreamento, que são capazes de reduzir a capacidade e a vida útil dos ambientes lênticos (Chelotti *et al.*, 2019). Compreender a distribuição espaço-temporal do material em suspensão é importante para o monitoramento e gerenciamento dos recursos hídricos a fim de proteger o ecossistema aquático (Chen *et al.*, 2016). O parâmetro também pode ser encontrado na literatura como total de sólidos em suspensão (TSS).

Para análise da dinâmica dos sedimentos em suspensão, alguns estudos adotaram fatores ambientais como velocidade/direção do vento e temperatura da água enquanto parâmetros de entrada para refinamento das equações preditivas (Robert *et al.*, 2017; Tu *et al.*, 2018). Os processos hidrológicos e atmosféricos afetam a variabilidade espaço-temporal do TSM (Robert *et al.*, 2017) e podem ser fundamentais para a precisão das estimativas.

Modelos empíricos e semi-empíricos foram amplamente utilizados nos últimos vinte anos para quantificação de TSM. São modelos simples e de fácil aplicação (Chen *et al.*, 2016) que relacionam estatisticamente dados *in situ* e valores de reflectância empregando, principalmente, análises de regressão linear e não linear, análise de componentes principais (ACP) e redes neurais artificiais (RNA) (Markert *et al.*, 2018). Com menor frequência, abordagens analíticas e semi-analíticas também foram aplicadas para quantificação de material em suspensão por meio de diferentes sensores e uso de modelos de inversão (Salama *et al.*, 2009; Jiang *et al.*, 2010; Dörnhöfer *et al.*, 2016).

Considerando as propriedades ópticas únicas da água, a porção vermelha do espectro eletromagnético ($\approx 625 - 740$ nm) é a mais relacionada à variação das concentrações de TSM (Chelotti *et al.*, 2019). Como a maioria dos sensores ópticos dos satélites de observação da Terra inclui pelo menos uma banda espectral no espectro vermelho, é natural que imagens de satélite em uma ampla faixa de resolução espacial tenham sido usadas para estimar as concentrações de TSM em oceanos, lagos e rios (Liu *et al.*, 2003). Desde a virada do século, houve um aumento significativo no número de missões de satélite usadas para monitorar a qualidade das águas. A Figura 2.5 apresenta os espectros da água sob dominância de TSM.

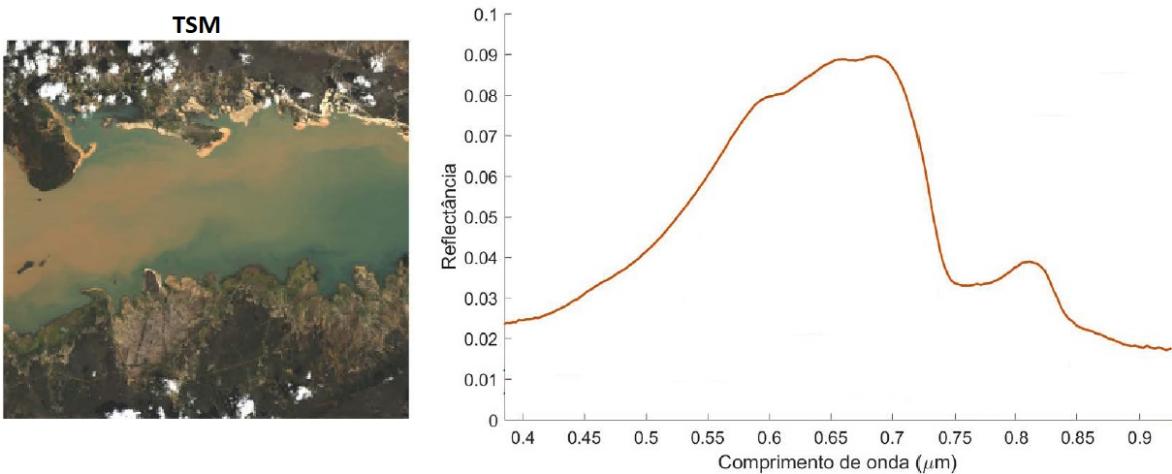


Figura 2.5: Espectros da água sob dominância de TSM.

Fonte: [Barbosa et al. \(2019\)](#).

O programa Landsat, que lançou o primeiro satélite em 1972 com os instrumentos *Multi Spectral Scanner* (MSS) e *Return Beam Vidicon* (RBV), foi continuado pelos instrumentos *Thematic Mapper/Landsat-4 e -5* (TM, lançado em 1982 no -4 e em 1984 no -5), *Enhanced Thematic Mapper/Landsat-7* (ETM+, lançado em 1999) e *Operational Land Image/Landsat-8 e -9* (OLI, lançado em 2013 no -8 e em 2021 no -9). As imagens dessas missões (e dos cinco satélites Landsat anteriores) mostraram um bom relacionamento entre as bandas visível e NIR com o TSM ([Alparslan et al., 2010](#)) indicando a vantagem adicional de oferecer possíveis séries temporais que remontam há quase 50 anos ([Tu et al., 2018](#)). Assim, foram apresentados resultados científicos integrando dados dos sensores TM, ETM+ e OLI para quantificar TSM por meio de abordagens empíricas usando as bandas vermelha e verde ([Markert et al., 2018](#)), bem como as bandas azul e vermelha ([Tu et al., 2018](#)). Outros autores tiveram sucesso usando apenas uma única banda do sensor OLI: somente o vermelho ([Chelotti et al., 2019](#)) ou apenas o NIR ([Robert et al., 2017](#)).

Recentemente, [Silva et al. \(2020\)](#) obtiveram bons resultados para monitoramento de alguns parâmetros de qualidade da água, incluindo TSM, usando RNA e bandas do espectro do visível. Sua abordagem combinou os dados Sentinel-2A (2015) e -2B (2017) da ESA/Copernicus por meio do sensor *Multi Spectral Imagers* (MSI) e OLI/Landsat-8 para criar uma série temporal de imagens no período 2014 – 2019. O instrumento MSI abrange a faixa espectral 433 – 2280 nm com resolução espacial de 10, 20 e 60 m. O sensor MSI também se mostrou útil para aplicação em águas com baixa concentração de sedimentos e baixa variabilidade espacial, adotando modelagem inversa e os comprimentos de onda centradas em 443 nm (banda 1) e 783 nm (banda 7) ([Dörnhöfer et al., 2016](#)). Em 2016, a ESA/Copernicus lançou o satélite Sentinel-3A, seguido pelo Sentinel-3B em 2018, projetado especificamente para monitoramento aquático (principalmente oceânico) com quatro instrumentos complementares: o *Ocean and Land Color Instrument* (OLCI), o *Sea and Land Surface Temperature Radiometer* (SLSTR), o *Synthetic Aperture Radar* (SAR) e *Altimeter* (SRAL) e um radiômetro de micro-ondas (*Microwave Radiometer* – MWR). Em particular, o instrumento OLCI com 21 bandas

espectrais estreitas (11,5 nm em média) e uma resolução espacial de 300 m foi criado para monitorar uma série de parâmetros de qualidade da água, incluindo TSM, turbidez e chl-a.

Utilizando dois sensores multiespectrais, multi-parâmetros e abordagens empíricas com multi-algoritmos, [Soomets et al. \(2020\)](#) e [Uudeberg et al. \(2020\)](#) encontraram conclusões semelhantes: o MSI e o OLCI mostraram melhores resultados para concentrações mais altas de TSM, com melhor desempenho do MSI. Em baixas concentrações (água de cor clara a moderada), os coeficientes de determinação (r^2) foram baixos para o OLCI ($< 0,5$). Ambos os estudos também testaram uma variedade de algoritmos, incluindo banda única, razão e álgebra de bandas complexas (14 algoritmos para estimativa de TSM em [Soomets et al.](#) e 39 em [Uudeberg et al.](#)) concluindo que algoritmos diferentes são melhores para diferentes tipos ópticos de água. Ambos encontraram o melhor modelo incluindo a faixa do *red-edge* (700 – 710 nm, [Soomets et al.](#)) ou uma banda NIR (810 nm, [Uudeberg et al.](#)). [Blix et al. \(2018\)](#) também descobriu que o OLCI teve baixo desempenho ($r^2 = 0,11 - 0,42$) para TSM no lago Balaton (Hungria), um corpo de águas complexas.

Os produtos MODIS e MERIS, ambos de alta resolução temporal (1 – 3 dias), foram utilizados em diversos estudos, incluindo o monitoramento de TSM das últimas duas décadas ([Salama et al., 2009](#); [Cui et al., 2013](#); [Philipson et al., 2016](#); [Chen et al., 2016](#); [Odermatt et al., 2018](#); [Cao et al., 2019](#)) mas principalmente para grandes lagos e reservatórios, dado que ambos os sensores têm uma resolução espacial moderada (250 a 1000 m, dependendo do produto). Para o MODIS, estudos sugerem que foram obtidos bons resultados com as bandas verde ([Chen et al., 2016](#)), vermelho ([Chelotti et al., 2019](#)), NIR ([Cui et al., 2013](#); [Robert et al., 2017](#)) e infravermelho de ondas curtas (*Short Wave Infrared – SWIR*) ([Chen et al., 2016](#)). Para o MERIS, as faixas verde ([Odermatt et al., 2018](#)) e vermelha ([Salama et al., 2009](#)) alcançaram melhores resultados.

Imagens de altíssima resolução espacial (*Very High Resolution – VHR*, < 1 m) também foram usadas com resultados muito bons para TSM (e outros parâmetros de qualidade da água) ([Pyo et al., 2018](#); [Sabat-Tomala et al., 2018](#); [Veronez et al., 2018](#); [Avdan et al., 2019](#); [Li et al., 2020](#)). Em particular, o estudo de [Sabat-Tomala et al. \(2018\)](#) usando o sensor hiperespectral HySpex alcançou um alto nível de detalhes de distribuição espacial e criou séries temporais com intervalos muito curtos para investigar a variabilidade sazonal de um reservatório inteiro próximo à cidade de Varsóvia (Polônia). Os autores descobriram que a equação espectral (algoritmo) de comprimento de onda 748 nm – 870 nm produziu os melhores resultados. O mesmo algoritmo foi aplicado aos produtos do MERIS fornecendo resultados igualmente satisfatórios.

Imagens VHR provenientes de sensores a bordo de UAVs também foram usadas com algum sucesso, inclusive pelo uso de câmeras de baixo custo. No entanto, em algumas dessas câmeras, o canal vermelho foi substituído por uma banda NIR de maneira que a faixa do vermelho torna-se indisponível ([Kupssinskü et al., 2020](#); [Veronez et al., 2018](#)). O TSM pode ser estimado usando essas câmeras ([Guimarães et al., 2019](#)). Sem a faixa vermelha (normalmente apropriada para estimar o TSM), as bandas verde e NIR foram usadas com sucesso por [Veronez et al. \(2018\)](#) ou mesmo as bandas azul, verde e NIR, como o estudo de [Kupssinskü et al. \(2020\)](#).

Concentração de clorofila-a (chl-a) e ficocianina (PC)

As comunidades fitoplanctônicas representam um dos parâmetros passíveis de detecção e monitoramento por sensores remotos. A análise do estado trófico e da qualidade da água de um lago ou reservatório está relacionada, entre outros fatores, com a abundância de fitoplâncton (Bresciani *et al.*, 2020). O aumento destas espécies é causado, principalmente, pela poluição da água (Peppa *et al.*, 2020). Altas cargas de nutrientes aceleram o crescimento e a produção de biomassa das algas (Pyo *et al.*, 2018) e podem ser associadas a florações de fitoplâncton (Wilkie *et al.*, 2019). Existe uma preocupação em torno da floração de cianobactérias pois elas podem, ou não, produzir metabólitos chamados cianotoxinas nos corpos d'água. Estas toxinas significam uma efetiva ameaça à saúde pública humana. A detecção via sensoriamento remoto de fitoplâncton em águas continentais, que podem se caracterizar por espécies de cianobactérias potencialmente produtoras de substâncias nocivas à saúde humana, baseia-se na estimativa remota de chl-a e PC (Ogashawara, 2019).

Normalmente, as florações de cianobactérias surgem no período da manhã devido ao processo respiratório ocorrido durante a ausência de luminosidade (Bresciani *et al.*, 2018). Fatores sazonais como elevação de temperatura e dinâmica dos ventos também influenciam na distribuição espacial (e ao longo da coluna d'água), abundância e diversidade de espécies fitoplancônticas (Bresciani *et al.*, 2020). O horário de surgimento das florações favorece o uso do sensoriamento remoto óptico para quantificar este parâmetro considerando a órbita e o horário de passagem dos satélites passivos.

Há uma diferença no comportamento de absorção e reflexão de luz no espectro eletromagnético entre águas com concentração predominante de fitoplâncton (Caso 1) e águas mais complexas, com altos níveis de turbidez, CDOM e TSM (Caso 2) (Malahela *et al.*, 2018). Diversos autores indicam a adequabilidade do uso de algoritmos de razão de reflectância entre as bandas azul/verde para o Caso 1 (Binding *et al.*, 2011; Watanabe *et al.*, 2018; Anper e Alikas, 2019; Zeng e Binding, 2019) enquanto o uso de bandas nas regiões espectrais do NIR e vermelho são mais aplicáveis a águas do Caso 2, uma vez que a interferência da resposta de partículas não-algais e CDOM são reduzidas consideravelmente nestas regiões (Cheng *et al.*, 2013). Além das razões de azul/verde e NIR/vermelho para estimar a concentração de chl-a, os estudos de quantificação frequentemente adotam um terceiro algoritmo baseado em curvatura espectral que utiliza razão de três bandas: são exemplos deste algoritmo *Fluorescence Line Height* (FLH, que utiliza uma banda centralizada em 685 nm) e *Maximum Chlorophyll Index* (MCI, que utiliza uma banda central a 706 nm) (Flores-Anderson *et al.*, 2020). A Figura 2.6 apresenta os espectros da água sob dominância de chl-a.

A quantificação de dados de chl-a e PC é possível por meio do imageamento hiperespectral. A diversidade de bandas dos sensores Hyperion (satélite EO-1) e CHRIS (Proba-1) permitiu a aplicação de mais de 100 índices hiperespectrais para modelagem da concentração de chl-a, atingindo um resultado robusto por meio de um algoritmo de quatro bandas que calcula o índice normal de clorofila (*Normal Chlorophyll Index – NCI*) utilizando as bandas 550 nm, 675 nm, 690 nm e 700 nm (Cheng *et al.*, 2013). O sensor Hyperion ainda se mostrou útil na aplicação em sistemas complexos com baixa concentração de chl-a (< 10 mg/m³) (Flores-Anderson *et al.*, 2020). O instrumento AisaFENIX é o sensor mais aprimorado da Specim e provou ser superior aos anteriores em relação aos estudos de qualidade da água: aliado a técnicas específicas de correção atmosférica, o sensor obteve bom de-

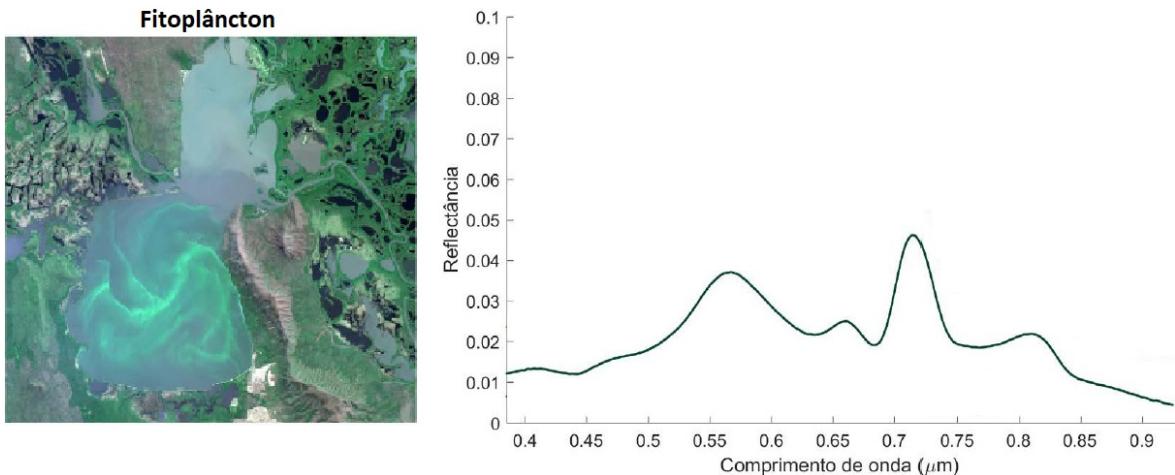


Figura 2.6: Espectros da água sob dominância de chl-a.

Fonte: [Barbosa et al. \(2019\)](#).

semepnho na quantificação de chl-a de um lago eutrófico por meio de um algoritmo semi-analítico (NIR/vermelho) ([Markelin et al., 2017](#)).

Embora exigindo custos logísticos mais altos decorrentes das campanhas aéreas, imagens provenientes dos sensores MIVIS e APEX também foram capazes de validar modelos numéricos 3D de lagos, identificando potenciais florações de algas com o uso de abordagens semi-empíricas de razão de banda tanto para o MIVIS (677 nm, 710 nm e 747 nm) quanto para o APEX (670 – 673 nm e 690 – 697 nm) ([Pinardi et al., 2015](#)). Sensores a bordo de UAVs são capazes de registrar imagens de alta e altíssima resolução (espacial e espectral). As bandas espectrais do visível e NIR referentes ao sensor hiperespectral PIKA-L foram utilizadas para estimar a chl-a e teve seus resultados comparados com os produtos de outros dois sensores: o multispectral WorldView-3 e o scanner hiperespectral aerotransportado (*Airborne Hyperspectral Scanner – AHS*) apresentando, entre eles, o melhor desempenho ([Eugenio et al., 2020](#)).

No decorrer dos últimos vinte anos, novos sensores foram desenvolvidos e testados para estimar chl-a e PC. Imagens multispectrais de altíssima resolução espacial, como WorldView-2 ([Ferreira e Galo, 2013](#)) e WorldView-3 ([Eugenio et al., 2020](#)) foram utilizadas para estimativa dos parâmetros. Embora os sensores apresentem resolução espacial muito refinada, a resolução espectral destes tem menor refinamento. Os resultados apresentados no estudo que envolve a plataforma mais evoluída (WorldView-3) foram considerados razoáveis mas, ainda assim, não foram capazes de capturar adequadamente a variação espacial de chl-a.

Os produtos da série Landsat estão entre as imagens de alta resolução aptas para quantificar a chl-a e a PC. Ainda que os sensores TM e ETM+ tenham sido usados na última década ([Novo et al., 2013; Ogashawara et al., 2014; Hansen e Williams, 2018](#)), o uso do sensor OLI vem sendo empregado desde seu lançamento em 2013, substituindo os antigos sensores com resultados eficazes por meio de modelos empíricos ([Watanabe et al., 2015; Malahela et al., 2018](#)).

O advento do instrumento MSI proporcionou aprimoramento dos resultados de estimativa da

qualidade da água tendo em vista as novas bandas na região do *red-edge* aliado à alta resolução espaço-temporal (as bandas do *red-edge* têm resolução espacial de 20 m e os sensores presentes nos satélites Sentinel-2A e -2B combinados permitem uma imagem a cada cinco dias). Estudos mostram que algoritmos empíricos que associam chl-a e a razão da faixa verde/vermelha apresentaram forte correlação com os dados coletados *in situ* (Ha *et al.*, 2017). Para as estimativas, algoritmos de duas, três e quatro bandas foram empregados com sucesso (Ha *et al.*, 2017; Anper e Alikas, 2019; Peppa *et al.*, 2020; Sòria-Perpinyà *et al.*, 2020). Alguns estudos investigaram simultaneamente o desempenho dos sensores OLI e MSI para quantificação de chl-a, o que comprovou boa performance de ambos, considerando que estes sensores não foram projetados exclusivamente para observação dos constituintes ópticos da água (Bresciani *et al.*, 2018; Watanabe *et al.*, 2018).

Parte de outra missão da ESA/Copernicus, o Sentinel-3 equipado com o sensor OLCI vem sendo estudado para detecção de chl-a e PC, seja pelo uso de algoritmos semi-empíricos (Ogashawara, 2019) ou pela modelagem semi-analítica (Zeng e Binding, 2019). O instrumento pode ser efetivo na quantificação dos valores de chl-a e PC devido à sua banda exclusiva centrada em 620 nm, assim como seu antecessor (MERIS), amplamente utilizado e eficiente para o desenvolvimento de algoritmos bio-ópticos (Ogashawara, 2019). Juntos, os sensores MSI e OLCI têm integrado recentes pesquisas científicas. Embora apresentem características diferenciadas, análises comparativas do desempenho dos sensores em ambientes lênticos usando algoritmos ML sugerem que a chl-a pode ser estimada com uma precisão muito semelhante em ambos (Pahlevan *et al.*, 2020). Modelos guiados por classificação óptica também apresentaram resultados relevantes, cuja performance indicou proveito levemente superior no uso do sensor MSI (Soomets *et al.*, 2020). Focando nas melhores características dos dois sensores, Bresciani *et al.* (2020) alcançaram uma compreensão mais aprimorada da dinâmica de fitoplâncton em diferentes escalas temporais e espaciais em um lago raso, turvo e eutrófico.

Matéria Orgânica Colorida Dissolvida (*Colored Dissolved Organic Matter – CDOM*)

É denominado CDOM o componente opticamente ativo que contém a fração colorida da matéria orgânica dissolvida na superfície da água (Coelho *et al.*, 2017; Sabat-Tomala *et al.*, 2018) podendo ser referido na literatura como matéria húmica, ácido limnohúmico e/ou gilvin (Brezonik *et al.*, 2005). É composto por um misto de moléculas orgânicas originárias de fontes alóctones (substâncias húmicas e fúlvicas derivadas do entorno da bacia de drenagem) e autóctones (fitoplâncton e outros organismos presentes no corpo d'água) (Menken *et al.*, 2006; Coelho *et al.*, 2017; Sabat-Tomala *et al.*, 2018). O CDOM é um importante indicador de qualidade da água a ser investigado uma vez que ele tem impactos na potabilidade da água (Chen *et al.*, 2017) e sua absorção da radiação solar resulta na proteção da biota aquática devido às reações fotoquímicas que ocorrem na interação da luz com a água (Kutser *et al.*, 2005). Este parâmetro ainda tem potencial para análise da dinâmica e compreensão do ciclo do carbono (Soomets *et al.*, 2020; Uudeberg *et al.*, 2020) sendo capaz de inferir indiretamente a quantificação do carbono orgânico dissolvido (DOC), um parâmetro NOA (Chen *et al.*, 2017).

O CDOM é um parâmetro difícil de ser quantificado em águas continentais complexas pois suas propriedades ópticas são semelhantes às substâncias orgânicas não vivas e organismos fito-

planctônicos presentes no TSM (Uudeberg *et al.*, 2020). A cor da água é um outro parâmetro opticamente ativo que contém características espetrais semelhantes às do CDOM, fato que os torna fortemente relacionados (Philipson *et al.*, 2016; Toming *et al.*, 2016).

A região azul do espectro eletromagnético é a mais influenciada pelo CDOM uma vez que o parâmetro absorve bem a luz visível em comprimentos de onda mais curtos, aumentando sua absorvância a medida em que o comprimento de onda diminui (Brezonik *et al.*, 2005; Uudeberg *et al.*, 2020). Esta característica torna mais complexa a análise por sensoriamento remoto em águas com níveis significativos de chl-a pois ela aumenta a reflectância nesta faixa do espectro (azul) onde o CDOM apresenta um decréscimo dos valores de reflectância (Menken *et al.*, 2006). A Figura 2.7 apresenta os espectros da água sob dominância de CDOM.

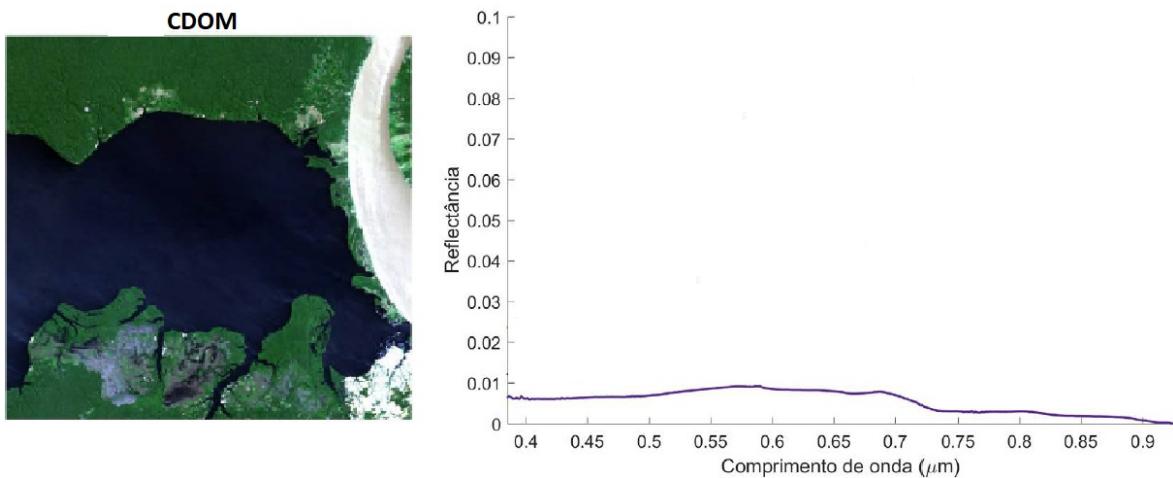


Figura 2.7: Espectros da água sob dominância de CDOM.

Fonte: Barbosa *et al.* (2019).

As propriedades ópticas dos ambientes lênticos possuem alto grau de variabilidade e podem implicar na restrição do desenvolvimento e aplicação dos algoritmos para detecção de CDOM (Coelho *et al.*, 2017). Sendo assim, a comunidade acadêmica tem trabalhado na construção e teste de diferentes algoritmos. Abordagens empíricas baseadas na razão de bandas entre as regiões do vermelho e verde são frequentemente encontradas na literatura atual (Kutser *et al.*, 2005; Menken *et al.*, 2006; Toming *et al.*, 2016; Chen *et al.*, 2017; Uudeberg *et al.*, 2020). Estas duas bandas são utilizadas preferencialmente devido ao fato de haver baixo sinal de saída da água e eventuais problemas associados às interferências atmosféricas comuns na região do azul (Toming *et al.*, 2016). Todavia, há estudos que fazem uso de modelagem empírica utilizando a faixa do azul por algoritmos de razão de bandas (675 nm/405 nm), mas apresentando baixos coeficientes de correlação entre os dados medidos e os dados previstos (Sabat-Tomala *et al.*, 2018). Houve sucesso por meio da análise de regressão utilizando o azul e o NIR (482 nm e 830 nm, $r^2 > 0,70$) em lagos e reservatórios (Brezonik *et al.*, 2005).

Os comprimentos de onda mais utilizados para medição *in situ* da absorvância do CDOM (aCDOM) estão a 400 nm, 412 nm e 442 nm (Soomets *et al.*, 2020), sendo o coeficiente a 440 nm o mais

comumente encontrado na literatura permitindo a quantificação por meio de métodos de inversão em sensoriamento remoto (Chen *et al.*, 2017). Algoritmos semi-empíricos de inversão baseados em transferência radiativa também apresentam grande potencial para quantificação da concentração de CDOM em águas rasas e profundas usando o comprimento de onda de 440 nm (Dörnhöfer *et al.*, 2016).

Os produtos dos sensores MERIS e Aqua/MODIS foram aplicados para quantificação e detecção de CDOM pela absorção na faixa de 440 nm em um lago boreal de coloração escura (Philipson *et al.*, 2016), em lagoas costeiras do Caso 2 (Giardino *et al.*, 2010) e em lagos com diferentes valores de concentração de matéria orgânica (Menken *et al.*, 2006). Verificou-se que quando os níveis de concentração de chl-a variam de moderado a alto, a quantificação de CDOM pode ser comprometida (Menken *et al.*, 2006).

O sensor OLCI/Sentinel-3 foi aplicado por técnicas de RNA na análise de parâmetros da qualidade da água em lagos altamente complexos e resultou em coeficientes de correlação baixos para concentração de CDOM (Blix *et al.*, 2018). O sensor também teve seu desempenho comparado ao instrumento MSI/Sentinel-2 em águas continentais opticamente diversas apresentando sempre uma performance inferior ao MSI (Soomets *et al.*, 2020; Uudeberg *et al.*, 2020). Comparado ao MSI, o OLCI possui algumas diferenças que podem ser determinantes nos resultados finais como a resolução espacial, mascaramento e correções atmosféricas presentes nas imagens (Soomets *et al.*, 2020).

A baixa resolução espacial restringe o monitoramento de lagos e reservatórios de pequeno porte (Al-Kharusi *et al.*, 2020). Desta forma, uma parte significativa das pesquisas científicas tem utilizado imagens de alta resolução espacial para estimativa de CDOM como produtos dos sensores REIS/RapidEye (Coelho *et al.*, 2017), ALI/EO-1 (Kutser *et al.*, 2005), TM/Landsat-5 (Brezonik *et al.*, 2005), OLI/Landsat-8 (Kutser *et al.*, 2016; Chen *et al.*, 2017) e MSI/Sentinel-2 (Dörnhöfer *et al.*, 2016). É importante ressaltar a não existência de um único comprimento de onda nem mesmo um único algoritmo adotados universalmente para estimar a concentração de CDOM, uma vez que este parâmetro sofre forte interferência espectral relacionada ao nível de concentração de outros COA, o que torna sua quantificação um desafio (Coelho *et al.*, 2017).

Profundidade do Disco de Secchi (*Secchi Disk Depth – SDD*)

O disco de Secchi (Figura 2.8) é um instrumento circular de diâmetro mensurado entre 20 e 30 cm, em geral preto e branco, preso a uma fita métrica e é dedicado à mensuração vertical da transparência da água através de sua imersão, onde a leitura é efetuada por um observador alocado na superfície da água (Liu *et al.*, 2019). A SDD é amplamente utilizada pela sua baixa complexidade de interpretação além de apresentar fácil aplicação (Torbick *et al.*, 2014). Esta medição tem como fundamento uma teoria de visibilidade subaquática (Vundo *et al.*, 2019). A atenuação da luz implica em maior ou menor clareza da água, que depende diretamente da concentração de substâncias em suspensão (Sabat-Tomala *et al.*, 2018), como fitoplâncton, matéria orgânica e inorgânica (Liu *et al.*, 2019). O melhor horário para estimar este parâmetro ocorre em torno de meio-dia (Avdan *et al.*, 2019). Entretanto, um fator de correção pode ser aplicado para compensar a variação da elevação solar (Verschuur, 1997).



Figura 2.8: Medição da transparência utilizando disco de Secchi.

A avaliação da transparência da água representa um fator importante no monitoramento e gestão dos recursos hídricos ([Bonansea et al., 2015](#)) por variadas razões. Atividades inseridas no entorno da bacia hidrográfica podem afetar a transparência da água devido ao carreamento de cargas de sedimentos e nutrientes ([Rodrigues et al., 2017](#)). Em clima temperado, o processo de proliferação de fitoplâncton, potencialmente modificador da clareza da água, atinge seu pico no final do verão e apresenta menor concentração durante a primavera, período este mais propenso a apresentar maiores valores de SDD em lagos e reservatórios ([Knight e Voth, 2012](#)). Já em clima tropical, especificamente em Minas Gerais, região de estudo, onde são considerados os períodos seco e chuvoso o processo é diferente. Na primavera, inicia-se o período de estratificação e assim, ocorre o aumento da produção primária na camada superficial de lagos e reservatórios. A vegetação aquática submersa está estreitamente associada à índices mais altos de transparência e qualidade da água, uma vez que esta vegetação age de modo a estabilizar o fundo do corpo hídrico limitando a ressuspensão de sedimentos, os níveis de nutrientes e a concentração de fitoplâncton ([Zhang et al., 2016](#)).

O monitoramento da transparência da água por sensoriamento remoto pode ser eficaz além de oferecer vantagens como, por exemplo, a possibilidade de criação de modelos baseados em imagens de satélite em que há a necessidade de poucos pontos amostrais levantados em campo ([Knight e Voth, 2012](#)). Os principais algoritmos de sensoriamento remoto aplicados para estimativa de SDD nos últimos vinte anos foram baseados em relações empíricas ou semi-analíticas ([Liu et al., 2019](#)).

A turbidez é um parâmetro que contém propriedades ópticas semelhantes às propriedades de SDD, o que pode permitir em alguns casos que a mesma combinação de bandas espectrais utilizadas para estimar SDD seja aplicada à estimativa de turbidez ([Avdan et al., 2019](#)). As regiões vermelha e azul do espectro eletromagnético são amplamente utilizadas para avaliação da clareza da água, uma

vez que a reflectância na faixa do vermelho é diretamente proporcional ao aumento da turbidez enquanto a reflectância na faixa do azul tende a diminuir (Knight e Voth, 2012). Combinações de bandas do visível (azul, verde e vermelho) têm sido frequentemente usadas na construção de algoritmos para estimativa de SDD em águas continentais opticamente complexas (Mancino *et al.*, 2009; Stefouli e Charou, 2012; Rodrigues *et al.*, 2017; Vundo *et al.*, 2019).

Modelos de sensoriamento remoto com bons níveis de significância para estimativa de SDD têm sido aplicados aos produtos MODIS (Liu *et al.*, 2019; Vundo *et al.*, 2019) e MERIS (Knight e Voth, 2012; Xiang *et al.*, 2015; Politi *et al.*, 2015; Zhang *et al.*, 2016) em corpos d'água de grandes extensões territoriais. As imagens provenientes destes sensores são adequadas para avaliar por meio da modelagem de dados a variação média da transparência da água em lagos que apresentam áreas maiores que 160 ha (Knight e Voth, 2012; Liu *et al.*, 2019).

Imagens dos sensores Landsat (TM, ETM+ e OLI) foram aplicadas em pesquisas científicas para mensuração de SDD, obtendo relações preditivas satisfatórias para os estudos específicos ($r^2 > 0,66$) em lagos e reservatórios (Mancino *et al.*, 2009; Huo *et al.*, 2014; Torbick *et al.*, 2014; Bonansea *et al.*, 2015; Xu *et al.*, 2018). Comparados os resultados dos algoritmos aplicados às imagens dos sensores OLI e MSI/Sentinel-2 em uma abordagem analítica, a resposta proveniente dos produtos OLI superou àquela relacionada aos produtos MSI, provando sua aplicabilidade em águas oligomesotróficas (Rodrigues *et al.*, 2017).

Estudos recentes têm empregado abordagens baseadas na classificação de tipos ópticos de água utilizando dados dos sensores MSI e OLCI de maneira a comparar seus resultados, provando superioridade nos índices de correlação entre os dados do sensor MSI e o SDD (Soomets *et al.*, 2020; Uudeberg *et al.*, 2020). Ainda que o sensor MSI tenha sido concebido para monitoramento terrestre, pesquisas atuais demonstram que o desenvolvimento de algoritmos e métodos específicos possibilitam bons resultados no uso de seus dados em ambientes aquáticos (Soomets *et al.*, 2020).

Turbidez

Turbidez é uma propriedade opticamente ativa da água que indica a presença, em maior ou menor grau, de partículas na coluna d'água e pode ser considerada uma medida da quantidade de luz espalhada ou absorvida (Potes *et al.*, 2012; Avdan *et al.*, 2019). Trata-se de um importante indicador da qualidade da água (Quang *et al.*, 2017) adotado por grande parte dos programas de monitoramento (Odermatt *et al.*, 2018). A turbidez pode ser provocada pela presença de material de origem fitoplânctônica, onde seu aumento é associado ao aumento dos pigmentos vegetais na coluna d'água (Sabat-Tomala *et al.*, 2018), ou de origem mineral proveniente da erosão dos solos (Menken *et al.*, 2006). Considerando as restrições específicas de cada indicador, TSM e turbidez podem ser considerados parâmetros correlacionados diretamente (Odermatt *et al.*, 2008). Outros materiais de origem biogênica, como zooplâncton, também podem alterar este parâmetro. A Figura 2.9 exemplifica diferentes níveis de turbidez da água registradas por sensoriamento remoto.

Em ambientes mais estáveis onde o fluxo d'água é baixo, pode ocorrer floração de fitoplâncton e processos de decomposição levando à altos índices de turbidez (Sabat-Tomala *et al.*, 2018). Estes números implicam em menor transparência da água e podem causar desequilíbrios e prejuízos para os



Figura 2.9: Exemplos de imagens de turbidez da água registradas por sensores remotos orbitais a bordo de satélites.

Fonte: [Barbosa et al. \(2019\)](#).

organismos biológicos ([Quang et al., 2017](#)). Um de seus efeitos pode ser representado pela alteração e aumento da temperatura medida na superfície aquática ([Potes et al., 2012](#)). A turbidez pode ser quantificada por nefelometria (NTU/FNU) ou estimada por disco de Secchi através de observações a partir da superfície ([Quang et al., 2017](#)). Entretanto, as observações por Secchi podem apresentar maiores incertezas se comparadas a outros métodos instrumentais de medição ([Son e Wang, 2019](#)).

Embora seja considerado um método eficaz, o uso do sensoriamento remoto para estimativa da qualidade da água em ambientes aquáticos continentais complexos com altos índices de turbidez ainda é um desafio ([Robert et al., 2017](#)). O uso da faixa espectral do vermelho em algoritmos de banda única podem produzir modelos extremamente consistentes e robustos para obtenção de turbidez em águas altamente turvas por meio de sensores de alta resolução, como o OLI ([Quang et al., 2017](#)). No entanto, o emprego de modelos de razão de duas ou mais bandas combinando diferentes bandas espectrais são mais comumente utilizados. Os modelos de duas bandas apresentaram boas estimativas utilizando imagens de baixa resolução espacial do MERIS adotando os comprimentos de onda 412 nm e 560 nm ([Potes et al., 2012](#)), bem como pelo uso de imagens de alta resolução dos sensores MSI ([Elhag et al., 2019](#)) e REIS ([Avdan et al., 2019](#)) combinando as bandas do verde e do vermelho. Bons resultados também foram alcançados no uso de dados hiperespectrais do HySpex scanner adotando as faixas do *red-edge* em 705 nm e 714 nm ([Sabat-Tomala et al., 2018](#)). Em geral, a literatura indica que uma boa precisão na estimativa de turbidez é possível empregando as bandas visíveis

(Silva *et al.*, 2020) e a combinação de bandas visíveis e infravermelhas (Alparslan *et al.*, 2010). Bons resultados são retratados na literatura, tanto no uso de modelos empíricos como analíticos, mas a escolha das regiões espectrais para o desenvolvimento do algoritmo para determinação de turbidez pode apresentar dependência de acordo com cada estação do ano, especialmente tratando-se de ambientes eutróficos (Barrett e Frazier, 2016).

Relação entre parâmetros não-opticamente ativos (NOA) e parâmetros opticamente ativos

Além dos parâmetros opticamente ativos, outros parâmetros físico-químicos e/ou biológicos com alto grau de importância podem ser utilizados como indicadores da qualidade da água. Estes indicadores podem ser classificados como parâmetros não baseados em cores e, portanto, NOA, onde grande parte dos estudos focou na estimativa de nitrogênio e fósforo (Li *et al.*, 2020). Embora a reflectância da água impossibilite a detecção dos parâmetros NOA, uma vez que as características ópticas e a relação sinal-ruído são relativamente baixas, eles podem ser inferidos indiretamente aos parâmetros opticamente ativos, como a chl-a, TSM e CDOM (Pu *et al.*, 2019). No entanto, os modelos NOA raramente são exportáveis para outras áreas (Topp *et al.*, 2020).

Técnicas de sensoriamento remoto são frequentemente aplicadas para estimativa de nitrogênio total (TN) e fósforo total (TP), especialmente por meio de modelos empíricos e algoritmos de otimização (Li *et al.*, 2017). O interesse em utilizar estas técnicas se deve à importância destes parâmetros. Água enriquecida com esses nutrientes geralmente resulta da irrigação em áreas agrícolas e mudanças no transporte de sedimentos (Alparslan *et al.*, 2010). Outra fonte importante de poluição é resultado do lançamento de esgotos domésticos. O nitrogênio é indispensável no processo de sintetização de proteínas, bem como o fósforo é essencial no processo de transferência de DNA, RNA e energia, tornando estes nutrientes aqueles que mais afetam a maioria dos ecossistemas aquáticos e terrestres (Liu *et al.*, 2015). A carga de nutrientes que causa a eutrofização de um lago ou reservatório é composta, principalmente, pela concentração de nitrogênio (nitrato ou amônia) e fósforo (fosfato) (Huo *et al.*, 2014). Há uma necessidade substancial de monitoramento dos ambientes lênticos, pois o fluxo destes nutrientes contribui com o desenvolvimento de plantas e fitoplâncton e pode culminar em florações de cianobactérias produtoras de toxinas (Torbick *et al.*, 2014) que representam um sério risco à saúde humana.

O índice de vegetação por diferença normalizada verde (*Green Normalized Difference Vegetation Index* – GNDVI) foi utilizado para estimar a concentração de TN utilizando as bandas NIR e verde do sensor MSI/Sentinel-2, uma vez que este índice é sensível à chl-a que, por sua vez, se relaciona com a concentração de nitrogênio (Elhag *et al.*, 2019). Sua fórmula original é composta pela Equação 2.1:

$$GNDVI = \frac{[\rho(NIR) - \rho(verde)]}{[\rho(NIR) + \rho(verde)]} \quad (2.1)$$

onde:

ρ = reflectância espectral referente ao comprimento de onda.

A temperatura da superfície aquática detectada por alguns sensores térmicos também é um importante preditor da estimativa de TN devido à sua correlação entre concentração e o desenvolvimento de micro-organismos aquáticos. A inclusão dos dados termais e variáveis de diferenças temporais entre aquisição da imagem e dos dados *in situ* possibilitaram mensurar a concentração de TN utilizando as bandas espectrais do azul, verde e NIR das imagens Landsat TM, ETM+ e OLI (Tu *et al.*, 2018). Métodos de regressão linear múltipla e RNA a partir de dados do satélite IKONOS demonstraram bons resultados de inversão na estimativa de TN com uso da banda única do verde (Liu *et al.*, 2015).

Os estudos para estimativa de TP avançaram significativamente nas últimas duas décadas. Alguns estudos (ainda inconclusivos) visam mostrar a existência de uma relação entre reflectância espectral e TP através de abordagens estatísticas (Xiong *et al.*, 2019). Um estudo envolvendo a reflectância proveniente das imagens do sensor ASTER e a concentração de fósforo indicou uma altíssima correlação por meio de um modelo quadrático incluindo uma banda SWIR (2145 nm – 2185 nm, $r^2 = 0,94$, RMSE = 0,014 mg/L), além de altos valores correlacionais com as bandas do SWIR B4, B5, B6, B7, B8 e as bandas do TIR B13 e B14 (Abdelmalik, 2018). Algoritmos analíticos ainda não foram empregados para estimativa de TP em sensoriamento remoto, tendo as aplicações utilizado métodos empíricos por derivação indireta ou derivação direta (Xiong *et al.*, 2019). A banda vermelha do satélite IKONOS (632 nm – 698 nm) apresentou bom desempenho na quantificação de TP por meio de correlação indireta com as propriedades ópticas de corpos d'água urbanos (Liu *et al.*, 2015). Em outro estudo, um algoritmo empírico por método de derivação direta se mostrou superior ao método indireto na aplicação em águas turvas utilizando os comprimentos de onda 645 nm e 1240 nm do instrumento MODIS/Aqua (Xiong *et al.*, 2019).

O carbono é também um composto de indicadores NOA da qualidade da água importante no monitoramento de lagos e reservatórios. O DOC apresenta altas correlações com o CDOM e, juntos, exercem funções significativas no ciclo do carbono, na potabilidade e nos ecossistemas aquáticos (Chen *et al.*, 2017). O carbono orgânico particulado (POC) está presente na biomassa de fitoplâncton e tem forte correlação com a chl-a (Hadjimitsis e Clayton, 2011). O carbono orgânico total (TOC) pode ter seu aumento ou diminuição atribuídos à presença de organismos planctônicos e à concentração de matéria orgânica (Abdelmalik, 2018). Os indicadores ligados ao carbono puderam ser corretamente estimados através de imagens provenientes de sensores de alta resolução, utilizando o MSI para estimar o DOC (pelos bandas do verde e do vermelho) (Toming *et al.*, 2016), os sensores TM e ETM+ para estimar o POC (com uso das faixas espectrais do azul e do verde) (Hadjimitsis e Clayton, 2011) e o ASTER para estimar o TOC (utilizando a faixa do NIR) (Abdelmalik, 2018).

Existem outros vários parâmetros NOA passíveis de estimação indireta por sensoriamento remoto e correlação destes com outras variáveis. A literatura ainda apresenta a previsão de concentrações como para: potencial de hidrogênio (pH) (Wang *et al.*, 2012; 2014; Abdelmalik, 2018; Pu *et al.*, 2019; Li *et al.*, 2020), condutividade elétrica (EC) (Abdelmalik, 2018; Avdan *et al.*, 2019), salinidade, alcalinidade (Abdelmalik, 2018), demanda química de oxigênio (COD) (Alparslan *et al.*, 2009; Wang *et al.*, 2012; 2014; Huo *et al.*, 2014; Xiang *et al.*, 2015; Pu *et al.*, 2019; Li *et al.*, 2020), absorção de material não pigmentado (Jiang *et al.*, 2010), demanda biológica de oxigênio (BOD) (Alparslan *et al.*, 2009; Wang *et al.*, 2012) e oxigênio dissolvido (DO) (Wang *et al.*, 2012; 2014; Pu *et al.*, 2019;

[Li et al., 2020](#)).

Bem como os parâmetros opticamente ativos, os NOA podem apresentar baixa correlação na classificação da qualidade da água e, até mesmo erros, caso haja grande diferença no intervalo entre as datas de amostragem e a data de passagem do satélite ou em decorrência da variação climática ([Tu et al., 2018](#); [Pu et al., 2019](#)). A alteração de um parâmetro NOA e as mudanças sazonais podem afetar os resultados de correlação entre os dados de qualidade da água e a reflectância. Frente a isso, é importante considerar a estação e a condição climática a qual o estudo está submetido ([Abdelmalik, 2018](#)).

2.2.5 Aplicações recentes das metodologias utilizadas em sensoriamento remoto e qualidade da água

Diante do cenário de pesquisa atual, onde o sensoriamento remoto pode ser usado como um importante instrumento na avaliação da qualidade da água, comprehende-se que as geotecnologias possibilitam a aliança à outras técnicas de forma a garantir métodos precisos de análise e modelagem dos recursos hídricos. Os dados provenientes dos sensores podem ser usados de maneira a alimentar os diferentes modelos ([Machado e Baptista, 2016](#)) auxiliando no desenvolvimento de novas metodologias empíricas (E) ou analíticas (A). A Tabela 1 (apêndice) apresenta uma síntese dos métodos mais utilizados descritos pela literatura recente levantados por meio do banco de dados *Scopus*.

2.3 Modelagem matemática e análise estatística aplicada aos parâmetros ópticos

O propósito desta seção é apresentar uma breve abordagem acerca da modelagem matemática da qualidade de águas superficiais e da análise dos resultados obtidos. A seguir, alguns conceitos importantes desta etapa da pesquisa serão revistos para compreensão do procedimento adotado.

2.3.1 Modelagem matemática da qualidade de águas superficiais no contexto do sensoriamento remoto de águas continentais

O planejamento e gerenciamento do uso dos recursos hídricos é fundamental para prevenir potenciais cenários de degradação ambiental. O uso dos modelos matemáticos é uma das formas de se evitar os impactos causadores de poluição, além de avaliar possíveis intervenções e medidas de controle necessárias ([Silva et al., 2017](#)), uma vez que estes modelos objetivam descrever o comportamento das concentrações dos componentes da água em uma análise espaço-temporal.

Modelos matemáticos são aqueles que refletem fenômenos da realidade representados de forma abstrata explicitada por equações matemáticas. Estes modelos podem ser definidos como uma concepção desenvolvida com a finalidade de responder a um sistema físico a partir de estímulos externos. Aplicados à qualidade da água, eles podem auxiliar na forma de um geossistema a resolução de problemas de contaminação ([Chapra, 1997](#)).

De maneira geral, os modelos matemáticos de qualidade da água são representações simplificadas da presença dos constituintes na água. [Wang et al. \(2013\)](#) ressaltam a eficácia dos modelos aliados à técnicas de sensoriamento remoto para a gestão ambiental na simulação e prevenção da poluição aquática e apontam sua importância na contribuição da redução de custos tendo em vista o número de experimentos laboratoriais que devem ser realizados para determinação da qualidade da água.

Os modelos matemáticos são construídos de maneira a compreender o funcionamento da estrutura interna de um sistema, programar campanhas de campo ou posicionamento de sensores e gerenciar o sistema de modo a obter o controle de potenciais intervenções a serem realizadas ([Benedetti e Sforzi, 1999](#)). A escolha de um determinado modelo depende, além das variáveis que irão compô-lo, de outros aspectos como os objetivos propostos e o tempo disponível ([Araújo, 2015](#)).

Para construir um modelo matemático universal, [Christofolletti \(1999\)](#) elucida a necessidade de provocar quatro indagações principais que envolvem a compreensão do problema, o estabelecimento de um plano para a resolução do problema, a execução do plano e a verificação da resposta. Para tanto, o autor estabelece um esquema de abordagem que pode ser verificado na Figura 2.10.

Inicialmente é necessário estabelecer o propósito para o qual o modelo será desenvolvido. Com os objetivos definidos, as hipóteses são articuladas e transformadas em formulações matemáticas. Após esta etapa, verifica-se a precisão das hipóteses bem como as equações propostas para dar início à calibração estabelecendo os parâmetros de entrada e condições internas do sistema. Todo processo da modelagem é finalizado com a checagem por meio da análise e avaliação do modelo ([Christofolletti, 1999](#)).

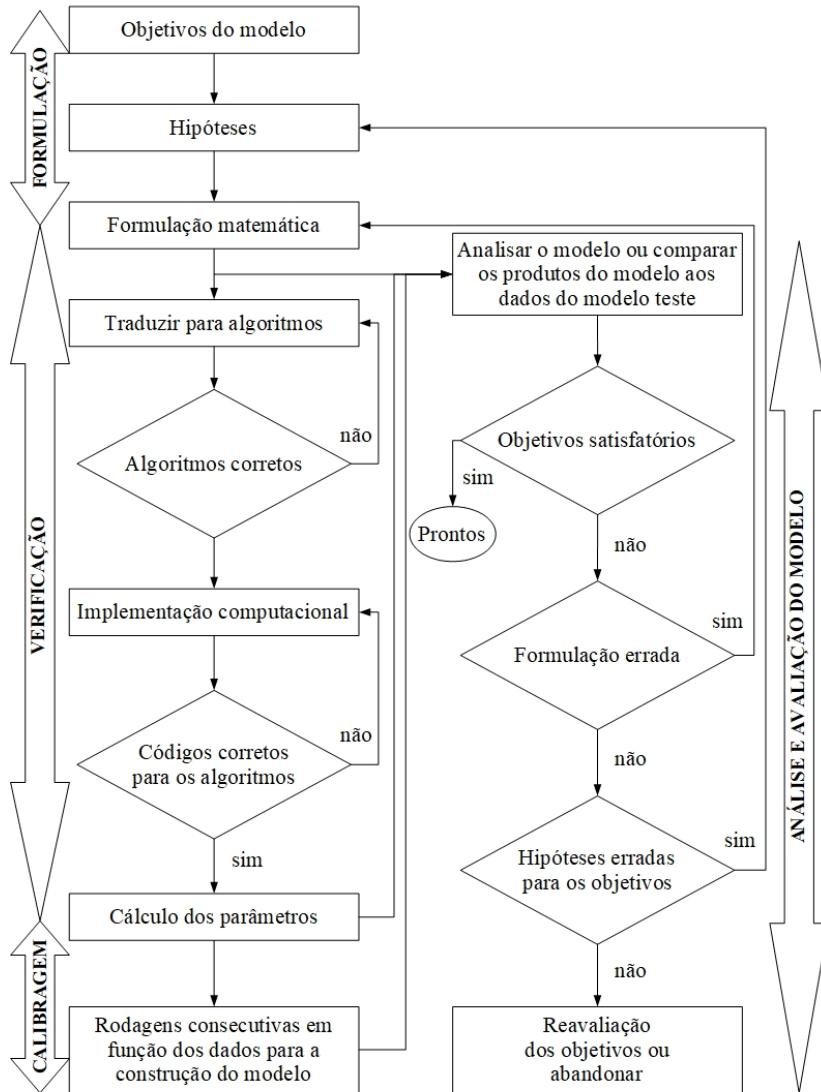


Figura 2.10: Esquema da abordagem clássica para o processo de modelagem.

Fonte: [Christofoletti \(1999\)](#).

O autor ainda estabelece, dentre outros campos de estudo, diferentes tipologias de modelos hidrológicos, podendo os modelos serem classificados com base em processos, em escalas temporais, em escalas espaciais ou em técnicas de resolução. Dentro da classificação baseada em processos, os modelos podem ser concentrados ou distribuídos.

É importante destacar que modelos hidrológicos se diferem de modelos específicos de qualidade da água. Estes últimos apresentam uma valiosa vantagem que diz respeito à possibilidade de utilização diferentes critérios para calibrar o modelo ([Rode et al., 2007](#)). Contudo, questões específicas envolvendo calibração e validação de um modelo de qualidade da água serão aprofundadas no tópico seguinte.

Existe uma dificuldade concreta que envolve a construção de modelos ambientais com a finalidade

de representar a forma como o mundo real é observado e medido, uma vez que dentre as múltiplas interações nos sistemas ambientais há diversas destas que não podem ser quantificadas (Von Sperling, 2007a). Entretanto, deve-se considerar que não há um modelo matemático único que se adéque perfeitamente a um universo de contextos e situações visto que, para a definição de um dado modelo, existe a necessidade de se observar as características específicas de cada sistema, seus relacionamentos, conflitos, objetivos, dados e recursos que poderão ser empregados (Jesus, 2006).

Diversos autores retrataram ao longo dos anos diferentes representações esquemáticas referentes ao desenvolvimento de um modelo matemático (Chapra, 1997; Tucci, 1998; Bassanezi, 2002; Von Sperling, 2007a; Naessens *et al.*, 2012). A Figura 2.11 apresenta essencialmente um fluxograma sintetizado com as principais etapas do processo de modelagem matemática.

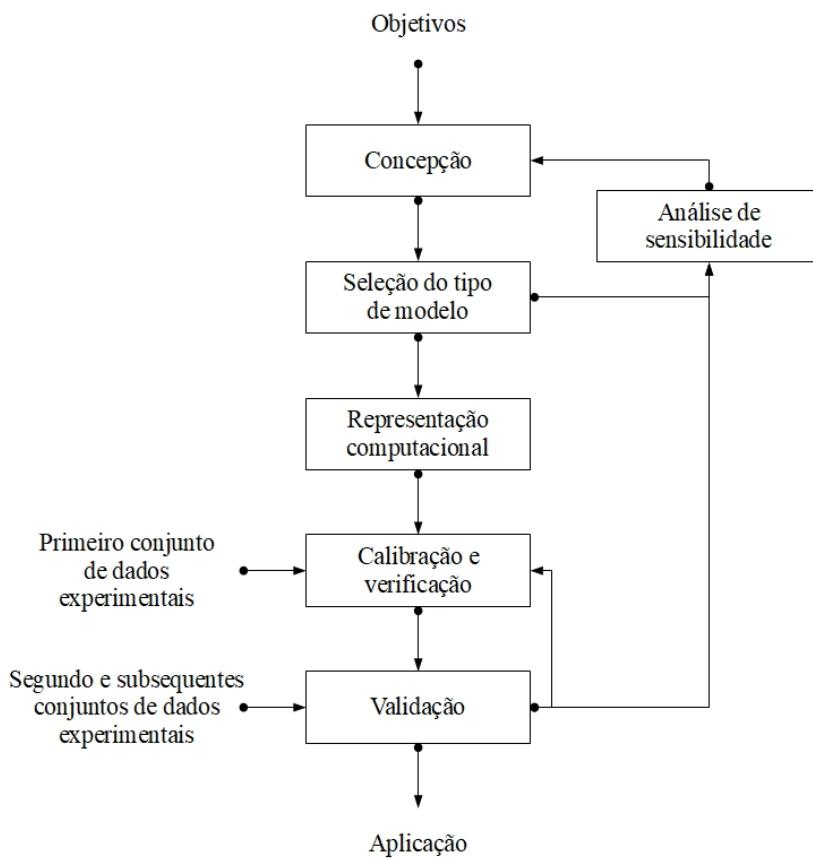


Figura 2.11: Etapas de desenvolvimento de um modelo matemático.

Fonte: Von Sperling (2007a).

Benedetti e Sforzi (1999) abordam a construção de modelos matemáticos aplicados à qualidade de água. Para eles, o processo de construção do modelo compreende o cumprimento de alguns passos que vão desde a concepção do problema e objetivos de gestão e controle até a aplicação do modelo (Figura 2.12).

Os modelos que melhor tentam explicar o mecanismo interno do processo de modelagem são os determinísticos. Estes modelos exigem um sólido conhecimento processual e da aplicação do modelo.

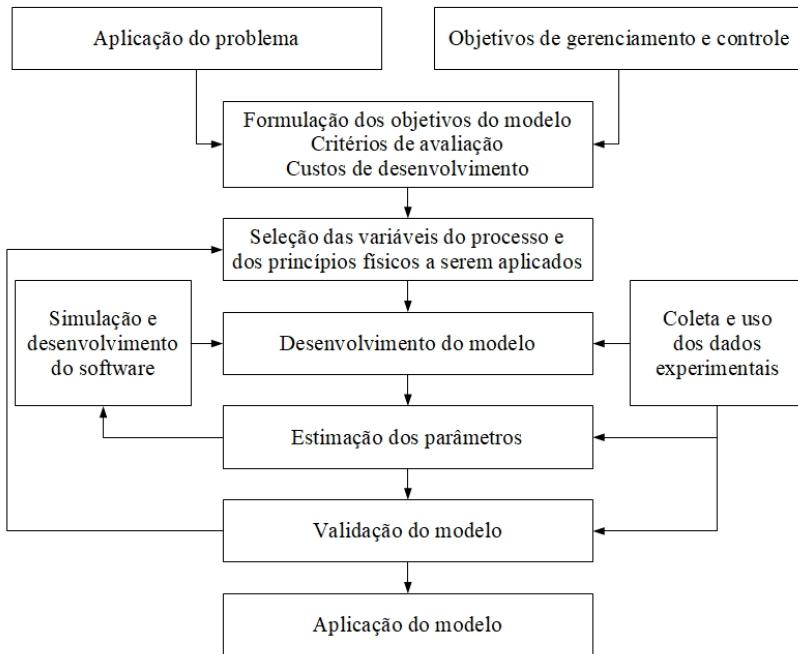


Figura 2.12: Passos necessário para a construção de um modelo de qualidade de água.

Fonte: adaptado de [Benedetti e Sforzi \(1999\)](#).

A complexidade inerente a estes modelos pode ser subjetiva e apresentar potenciais limitações quanto ao objetivo final do modelo ([Benedetti e Sforzi, 1999](#)).

Segundo revisão realizada por [Costa et al. \(2019\)](#), foram produzidos mais de 1000 artigos sobre modelos de qualidade da água nos últimos 20 anos, sendo aproximadamente 150 publicações apenas no ano de 2017. Esta listagem considera os sete modelos mais frequentemente usados nestes estudos ponderando os maiores números de incidências e documentação das aplicações dos modelos em vários países.

Percebe-se um aumento significativo das publicações nos últimos 10 anos relacionado ao uso do sensoriamento remoto aplicado à modelagem da qualidade das águas continentais, onde foram publicados duas vezes mais estudos do que nos 30 anos anteriores combinados: estes dados mostram crescimento consideravelmente mais rápido se comparado ao número total das publicações acadêmicas ([Topp et al., 2020](#)).

Os modelos matemáticos de qualidade da água em sensoriamento remoto são elaborados em função da relação entre os parâmetros e as respostas ópticas do ambiente aquático. A estimativa dos indicadores é realizada por meio da aplicação do modelo às imagens produzidas pelos sensores e sua validação ocorre pela comparação entre o resultado obtido e a concentração dos componentes medidos *in situ* e/ou coletados e obtidos em laboratório ([Barbosa et al., 2019](#)). A Figura 2.13 apresenta o fluxograma contendo as principais etapas de medição das grandezas radiométricas, processamento e modelagem dos COAs.

[Von Sperling \(2007b\)](#) elenca os métodos estatísticos mais frequentemente aplicados à qualidade

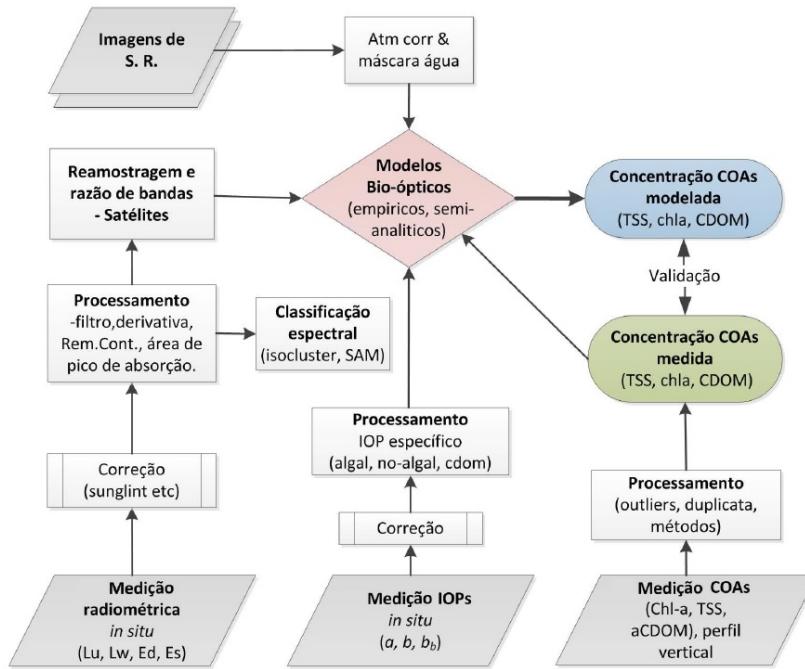


Figura 2.13: Fluxograma das principais etapas da modelagem dos constituintes da água.

Fonte: [Barbosa et al. \(2019\)](#).

das águas, comumente utilizados na etapa da estatística analítica, que são:

- testes de hipóteses;
- análise de dados qualitativos;
- análise de regressão e;
- análise de variância.

As abordagens que utilizam métodos estatísticos são comuns em estudos de diagnósticos de qualidade da água, sobretudo, as técnicas de regressão estão entre as mais frequentemente aplicadas ([Mianali et al., 2019](#)). As análises de regressão lineares múltiplas em sensoriamento remoto foram desenvolvidas para correlacionar os valores dos parâmetros coletados *in situ* (variável dependente) e as médias espectrais das bandas de cada janela estipulada para este modelo (variável independente). Algoritmos empíricos aliados a técnicas de regressão estatística podem fornecer resultados robustos quando aplicados a áreas de estudo específicas ([Matthews, 2011](#)).

Abordagens empíricas e/ou analíticas variadas vem sendo utilizadas na quantificação dos constituintes das águas continentais. Os métodos empíricos relacionam as bandas espectrais das imagens com os parâmetros de qualidade da água enquanto os métodos analíticos se baseiam em equações de transferência radiativa explorando as relações físicas entre absorção, coeficiente de dispersão e parâmetros de qualidade da água ([Van Nguyen et al., 2020](#)). [Mishra et al. \(2017\)](#) apontam uma falta de consistência na literatura referente à terminologia adotada aos modelos ópticos e os classifica em cinco categorias que são, resumidamente:

- a) EMPÍRICOS: concentram-se apenas em estimadores estatísticos;
- b) SEMI-EMPÍRICOS: baseiam-se em características espectrais específicas de absorção e espalhamento dos componentes da água que irão influenciar na refletância obtida;
- c) ANALÍTICOS: baseiam-se apenas nas propriedades físicas dos constituintes da água por inversão de equações de transferência radiativa de modo a estabelecer relações entre AOPs e IOPs;
- d) SEMI-ANALÍTICOS: nestes modelos, a estimativa do coeficiente de absorção espectral total é calculada pela soma da absorção de fitoplâncton, absorção de partículas não-algais e aCDOM;
- e) QUASI-ANALÍTICOS: a diferença destes modelos para os semi-analíticos é que nestes o conhecimento sobre outros coeficientes de absorção não é necessário, pois o coeficiente de absorção espectral total é estimado diretamente da reflectância e sua decomposição é utilizada para calcular os os demais coeficientes.

Metodologias que empregam técnicas de ML ([Huo et al., 2014](#); [Ruescas et al., 2018](#); [Kupsinskü et al., 2020](#); [Pahlevan et al., 2020](#)) e RNA ([Ferreira e Galo, 2013](#); [Veronez et al., 2018](#); [Pu et al., 2019](#)) foram eficazes na quantificação da concentração de COAs, como chl-a, TSM e CDOM. Os algoritmos ML têm sido utilizados para melhorar as estimativas e precisão de modelos apoiados em métodos empíricos possibilitando a modelagem dos dados por relações não-lineares ([Kupsinskü et al., 2020](#)). Relações não-lineares podem ser vantajosas pois elas apresentam com frequência bom desempenho na precisão e no viés com baixo custo computacional ([Ruescas et al., 2018](#)).

RNA podem ser hábeis no ato de inferir no espaço variáveis ambientais com o uso do sensoriamento remoto ([Ferreira e Galo, 2013](#)). As abordagens em torno de RNA em sensoriamento remoto podem ser atribuídas, resumidamente, a quatro competências:

- a) APRENDIZAGEM de padrões complexos;
- b) GENERALIZAÇÃO em ambientes ruidosos;
- c) INCORPORAÇÃO de conhecimento prévio dos dados, bem como restrições reais da análise efetuada e;
- d) INCORPORAÇÃO de dados de diferentes sensores e auxiliares na análise, caso não haja nenhum tipo de suposição aplicável aos dados ([Mas e Flores, 2008](#)).

As produções em sensoriamento remoto aquático incluem pesquisas por RNAs aplicadas à determinação de diferentes índices de trofia em lagos ([Ha et al., 2017](#)), estimativa dos índices de concentração de chl-a ([Ferreira e Galo, 2013](#)), determinação da correlação entre TSM e matéria orgânica dissolvida ([Veronez et al., 2018](#)), modelagem dos índices de qualidade da água por redes convolucionais ([Pu et al., 2019](#)), entre outras aplicações.

2.3.2 Calibração e validação de modelos ópticos

Os modelos seguem etapas onde pode haver ocorrência de processos iterativos até que se alcance um resultado satisfatório. A calibração e a validação são etapas finais essenciais que irão ajustar a modelagem de maneira que seja possível sua aplicação. O modelo deve representar o mundo real e, para preservar este realismo comprovando o potencial preditivo do mesmo, todo e qualquer modelo exige calibração e validação experimental (Naessens *et al.*, 2012). A confiabilidade de um modelo garante o bom desempenho dos parâmetros que este modelo deseja representar (Mulligan e Brown, 1998). Para calibrar e/ou validar um modelo a partir de dados de sensoriamento remoto é fundamental compreender a dinâmica hidrológica e o funcionamento do ambiente estudado (Barbosa *et al.*, 2019).

A calibração é também conhecida como um processo de estimativa dos parâmetros (ou coeficientes) integrantes das equações (Von Sperling, 2007a). Esta etapa objetiva identificar e ajustar os melhores valores a fim de parametrizar o modelo (Beck, 1983). Entretanto, esta é considerada a etapa mais difícil do processo de modelagem da qualidade da água (Mulligan e Brown, 1998). A complexidade desta tarefa se deve a três tipos de incertezas: incerteza na expressão matemática do sistema, no controle dos experimentos ambientais e nos dados de campo (Beck, 1983). É necessário quantificar e compreender estas incertezas associadas à modelagem pois desta forma é possível realizar interpretações relevantes da saída do modelo (Cox, 2003).

O estágio de calibração compreende a verificação do desempenho do modelo. Esta verificação ocorre de maneira a analisar os erros gerados em relação aos dados observados e os dados estimados (também conhecido como resíduos) (Von Sperling, 2007a). Para simplificar a análise do erro e avaliar a precisão do modelo de sensoriamento remoto pode-se empregar métodos estatísticos a fim de comparar estes dois valores como o erro médio quadrático (*Root Mean Square Error* – RMSE) e o erro sistemático (viés ou *bias*). Outra forma de analisar a precisão da modelagem ocorre pela divisão dos dados em conjuntos de treinamento e teste (Koponen, 2006). É importante ressaltar que há uma necessidade indispensável de um bom ajuste da calibração e validação dos modelos que utilizam dados de sensoriamento remoto com mensurações *in situ*, o que pode representar uma restrição no uso do modelo (Gholizadeh *et al.*, 2016). Para a qualidade da água estas medições de radiância e irradiância *in situ* são necessárias a fim de parametrizar, calibrar e validar os algoritmos (Barbosa *et al.*, 2019). Se há uma quantidade de parâmetros suficiente, um modelo pode ser ajustado de maneira a apresentar o mínimo de resíduos (Beck, 1983).

Executada a etapa de calibração com sucesso, a validação do ajuste do modelo é feita utilizando condições diferenciadas àquelas empregadas na calibração (Von Sperling, 2007a). Validação é o estágio da modelagem onde são testado outros conjuntos de dados de forma a medir a capacidade de previsão do modelo: se ele apresentar falhas é necessário retornar às etapas que antecedem a validação; caso contrário, o modelo está pronto para ser aplicado (Naessens *et al.*, 2012). Este processo serve para comprovar a precisão dos coeficientes escolhidos anteriormente (Fleck *et al.*, 2013).

Em ambientes aquáticos complexos, a validação dos modelos de sensoriamento remoto pode ser desafiadora em função da grande variabilidade de constituintes da água (Barbosa *et al.*, 2019). Na verdade, esta etapa busca comprovar ao pesquisador as hipóteses inválidas do modelo levando-o a obter aproximações melhores da realidade, uma vez que um modelo não pode nunca ser completamente

validado ([Beck, 1983](#)).

2.3.3 Limitações dos modelos de qualidade da água por técnicas de sensoriamento remoto

Ainda que a modelagem matemática se apresente como uma importante ferramenta para analisar a dinâmica e investigar as mudanças nos ambientes aquáticos é necessário salientar as limitações inerentes a ela. Alguns autores ([Christofolletti, 1999](#); [Novotny, 2002](#)) levantam como um grande limitador a avaliação da acuidade ou ajuste dos cenários previstos. Além disso, existe uma dificuldade efetiva em se estabelecer valores aos parâmetros do modelo bem como de identificar estes valores com os parâmetros que podem ser medidos no mundo real.

O sensoriamento remoto apresenta uma série de vantagens no uso de suas técnicas para estimativa de qualidade de água em lagos e reservatórios. A cobertura espaço-temporal, a análise em corpos d'água inacessíveis e a recuperação de dados históricos por séries temporais são algumas destas vantagens ([Ansper e Alikas, 2019](#); [Zhao et al., 2020](#)). Entretanto, é necessário mencionar a existência de restrições que são inerentes às suas aplicações. A dependência de boas condições climáticas para estimar estes parâmetros, bem como as mudanças originárias de massas de ar e a luminosidade do sol podem ser considerados fatores limitantes nesta quantificação ([Ansper e Alikas, 2019](#)). As imagens produtos dos sensores ópticos podem apresentar interferências atmosféricas capazes de afetar negativamente os resultados alcançados ([Veronez et al., 2018](#)).

A resolução dos sensores pode se tornar um obstáculo na avaliação da qualidade da água para pequenos lagos e pequenos reservatórios. Imagens de resolução baixa ou moderada como MODIS (250–1000 m), Sentinel-3/OLCI (300 m) ou Proba-V (300–600 m) podem ter aplicação muito limitada para corpos d'água menores que 2500 km² devido ao grande número de pixels com uma mistura de terra e água que podem implicar em incertezas das estimativas ([Mertes et al., 2004](#); [Cui et al., 2013](#); [Veronez et al., 2018](#)). Da mesma forma, sensores com baixa resolução espectral podem não ser apropriados para monitorar parâmetros de qualidade da água que podem estar relacionados a porções muito específicas do espectro eletromagnético. Isto ocorre, por exemplo, com a PC que possui o pico de absorção no comprimento de onda a 620 nm ([Ogashawara, 2019](#)) ou com a chl-a que é melhor quantificada com sensores que apresentam a banda do *red-edge* (\approx 690 – 740 nm). Ao contrário, sensores de altíssima resolução espacial são encontrados principalmente em satélites comerciais e podem apresentar um custo proibitivo para pesquisas em grandes lagos e reservatórios. O mesmo se aplica à maioria dos sensores hiperespectrais que estão disponíveis apenas para operações aéreas (com exceção do EO-1/Hyperion, desativado em março de 2017).

A resolução temporal ou capacidade de revisita é outro fator que pode impedir o monitoramento efetivo se a frequência desejada for menor que a capacidade de revisita do satélite ou se as condições atmosféricas locais não permitirem céu claro com frequência suficiente ([Veronez et al., 2018](#)). Há também a probabilidade de ser necessário realizar medições *in situ* sincronizadas com a passagem do sensor, o que pode impor outras restrições pois isso nem sempre é possível ([Wilkie et al., 2019](#)).

Os corpos d'água continentais são frequentemente muito complexos e variam enormemente de

uma região para outra. Como tal, é geralmente desaconselhável comparar as concentrações medidas por sensoriamento remoto de um corpo de água para outro, uma vez que alguns algoritmos precisam ser calibrados localmente e podem não ser replicáveis em outras áreas (Odermatt *et al.*, 2018) especialmente se essas áreas estiverem distantes e sujeitas a diferentes condições ambientais. As concentrações dos constituintes da água podem ser influenciadas pela vegetação submersa ou por outras fontes provenientes do fundo e podem afetar diretamente a radiância/reflectância na superfície e produzir estimativas falsas (Cui *et al.*, 2013). Como o sensoriamento remoto é restrito a medições em águas superficiais, apenas um número limitado de modelos podem ajudar a explicar o comportamento dessas partículas em suspensão ao longo da coluna d'água (Markert *et al.*, 2018).

O sensoriamento remoto ainda não permite certos resultados que dependem de análise local. Por exemplo, a técnica é útil para verificar o padrão de distribuição e densidade de cianobactérias, porém não quantifica concentrações de toxinas presentes na água, fator fundamental para a avaliação destes riscos (Van der Merwe e Price, 2015). Em relação aos materiais suspensos, embora suas estimativas de concentração sejam eficazes utilizando imagens de satélite, não é viável utilizar o resultado da detecção como entrada para modelagem de transporte de sedimentos devido a impossibilidade de quantificar todos os sedimentos presentes no corpo d'água (Markert *et al.*, 2018).

Por fim, muitos parâmetros importantes não podem ser medidos diretamente simplesmente porque não afetam as propriedades ópticas da água nos comprimentos de onda (largura e posição) usados pelos sensores disponíveis. Embora algum sucesso tenha sido obtido na estimativa desses parâmetros por causa de sua relação com outros parâmetros opticamente ativos, essas abordagens são essencialmente empíricas. Um melhor entendimento dessas relações exigirá modelos complexos envolvendo muitos parâmetros, alguns dos quais não podem ser estimados por sensoriamento remoto. Entretanto, é necessário ressaltar que, ainda que exista um longo caminho a ser percorrido para o aperfeiçoamento da estimativa destes indicadores, a comunidade científica vem se esforçando continuamente para desenvolver modelos que contornem estes obstáculos.

Capítulo 3

MATERIAIS E MÉTODOS

A METODOLOGIA desenvolvida na presente tese foi resumida e representada na Figura 3.1. As etapas do processo para alcançar os resultados propostos estão descritas nas seções subsequentes a este capítulo.

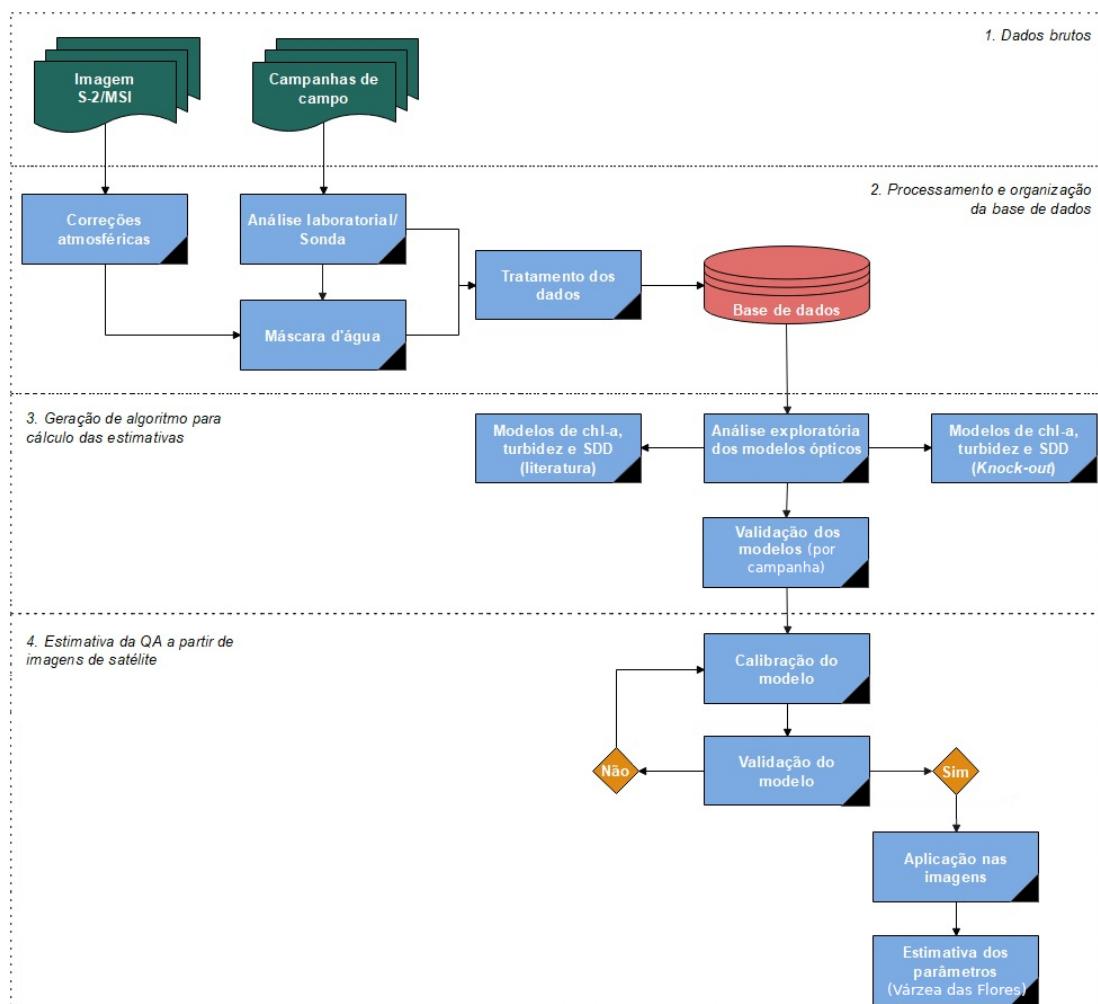


Figura 3.1: Fluxograma metodológico.

As principais etapas metodológicas desta pesquisa foram agrupadas em:

1. DADOS BRUTOS: aquisição das imagens do satélite Sentinel-2/MSI e aquisição dos dados referentes às oito campanhas de campo realizadas entre 2019 e 2021;
2. PROCESSAMENTO E ORGANIZAÇÃO DA BASE DE DADOS: processamento dos dados de satélite, análises laboratoriais, organização dos dados adquiridos pela sonda multiparâmetros e extração das máscaras d'água do Reservatório de Três Marias. Nesta etapa, os dados são tratados e organizados em uma base única;
3. GERAÇÃO DE ALGORITMOS PARA CÁLCULO DAS ESTIMATIVAS: análise exploratória dos modelos ópticos de chl-a, turbidez e SDD, de forma a aplicar os modelos descritos na literatura e avaliar as variáveis representadas pelas bandas espectrais por meio do método *Knock-out*. Aqui, os modelos são validados por campanha configurando o melhor ajuste para a etapa posterior;
4. ESTIMATIVA DA QUALIDADE DA ÁGUA A PARTIR DE IMAGENS: calibração e valida-ção dos modelos propostos, aplicação dos modelos às imagens dos dias de campanha, estimativa dos parâmetros de qualidade da água do Reservatório de Três Marias e aplicação dos modelos em séries temporais.

3.1 Área de estudo

3.1.1 O Reservatório de Três Marias

O Reservatório de Três Marias, que leva como nome oficial “Reservatório Bernardo Mascarenhas”, teve sua construção iniciada em 1957 e finalizada em 1961, sendo este um dos reservatórios mais antigos do país ([Cachapuz, 2006](#)). De acordo com os dados divulgados pela CEMIG, o reservatório apresenta área útil de inundação de 1090 km² e cerca de 20 bilhões de m³ de volume máximo, sendo útil mais de 15 bilhões de m³ (máximo). Com estas dimensões, o reservatório se insere entre os dez maiores reservatórios brasileiros quanto à área, ocupando a nona posição, e entre os dez maiores reservatórios do país quanto ao volume, ocupando a sexta posição ([Von Sperling, 1999](#)). As Tabelas [3.1](#) e [3.2](#) apresentam os dados de área e volume, respectivamente, dos maiores reservatórios do Brasil.

Localizado no Alto São Francisco (região Central do Estado de Minas Gerais) e inserido no contexto hidrográfico da Bacia do Rio São Francisco, o Reservatório de Três Marias está situado entre os paralelos 18°10' e 19°00' de latitude sul e os meridianos 44°50' e 45°35' de longitude oeste, se limitando a sul na confluência do Ribeirão da Marmelada com o Rio São Francisco, a leste pela rodovia MG-164, a oeste pela MG-060 e a norte pela barragem, aonde se localiza a Usina Hidrelétrica de Três Marias sob a concessão da CEMIG. No total, somam-se oito municípios limítrofes ao reservatório. São eles: Abaeté, Biquinhas, Felixlândia, Morada Nova de Minas, Paineiras, Pompéu, São Gonçalo do Abaeté e Três Marias (Figura [3.2](#)). Seus principais afluentes são os rios Borrachudo, Indaiá, Pará e Paraopeba, sendo o Rio São Francisco o curso principal ([Pinto et al., 2014](#)).

Tabela 3.1: Os dez maiores reservatórios brasileiros de acordo com a área.

Nome	Localização	Área (km ²)
Sobradinho	Bahia	4214
Tucuruí	Pará	2430
Balbina	Amazonas	2360
Porto Primavera	São Paulo/Mato Grosso	2140
Serra da Mesa	Goiás/Tocantins	1784
Itaipu	Paraná	1350
Furnas	Minas Gerais	1340
Ilha Solteira	São Paulo/Minas Gerais	1260
Três Marias	Minas Gerais	1090
Peixe	Goiás	940

Fonte: [Von Sperling \(1999\)](#).

Tabela 3.2: Os dez maiores reservatórios brasileiros de acordo com o volume.

Nome	Localização	Volume (km ³)
Serra da Mesa	Goiás/Tocantins	54,4
Tucuruí	Pará	45,5
Sobradinho	Bahia	34,1
Itaipu	Paraná	29,0
Ilha Solteira	São Paulo/Minas Gerais	21,2
Três Marias	Minas Gerais	21,0
Furnas	Minas Gerais	20,9
Porto Primavera	São Paulo/Mato Grosso	19,9
Emborcação	Minas Gerais/São Paulo	17,6
Balbina	Amazonas	17,5

Fonte: [Von Sperling \(1999\)](#).

O reservatório se caracteriza pela forma altamente dendrítica, tem profundidade máxima de 56 metros e se insere na faixa de transição entre os biomas Mata Atlântica e Cerrado ([Barbosa et al., 2014](#)). Possui ambiente considerado de acumulação e sofre com a diminuição do nível de água no período seco, especialmente entre os meses de julho e novembro ([Coelho, 2006](#)). Em 2014, a região do Alto São Francisco enfrentou uma grave crise hídrica sendo considerada a pior seca monitorada em 70 anos e uma das piores secas monitoradas na calha do Rio São Francisco ([IGAM, 2015](#)). Devido à estiagem acometida, o reservatório que alcançou volumes úteis acima de 80% em 2012 atingiu uma drástica redução do seu volume em 2014 chegando a operar com 2,58% da sua capacidade total ([ANA, 2015](#)).

De acordo com a classificação climática de Köppen-Geiger, adotada em larga escala em caracterizações climatológicas ([Guimarães et al., 2010](#)), a área de estudo apresenta clima, predominantemente, tropical de savana (Aw), quente e úmido com inverno seco e verão chuvoso. A temperatura média anual varia entre 19°C e 23°C, sendo que as temperaturas mais amenas ocorrem nas proximidades do reservatório ([Castilho, 1996](#)).

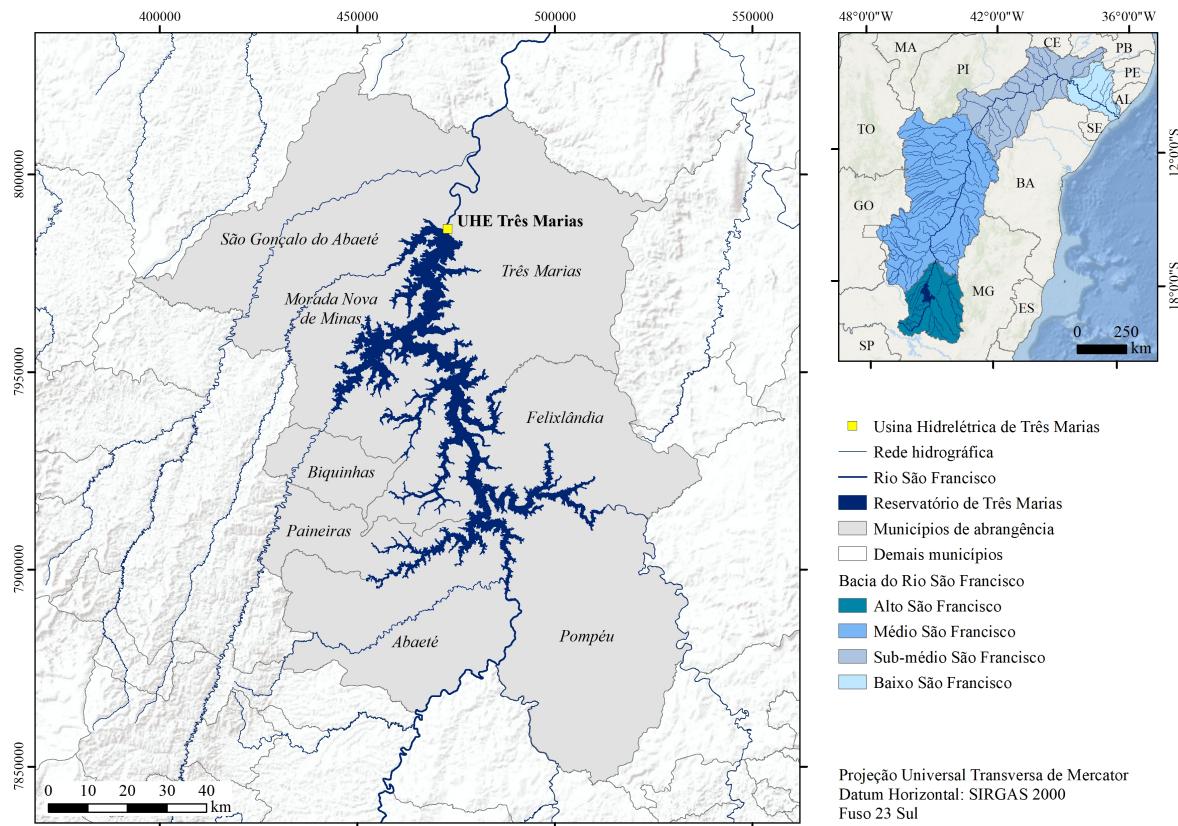


Figura 3.2: Mapa de localização do Reservatório de Três Marias.

A maior altitude registrada na área do reservatório apresenta cota de, aproximadamente, 950 metros a norte do município de Morada Nova de Minas e está inserida no contexto da Serra Vermelha. A menor cota registra a altitude de 510 metros e está inserida a jusante do reservatório, após o barramento, no percurso do Rio São Francisco.

A análise do uso e cobertura do solo permitiu identificar diferentes atividades realizadas no entorno da represa. A literatura ressalta uma real necessidade de compreensão acerca da dinâmica da área de estudo e de seu entorno para o diagnóstico da qualidade da água (Barbosa *et al.*, 2019; Carpenter *et al.*, 2011; Von Sperling, 2007a). As atividades no entorno do reservatório podem resultar em uma série de impactos, como supressão da vegetação marginal (expondo o solo e carreando material orgânico e nutrientes) e a incrementação de micronutrientes (como nitrogênio e fósforo), fatores que contribuem para o desenvolvimento de algas e consequente deterioração da qualidade da água (Ferreira *et al.*, 2020).

As atividades com maior potencial poluidor que impactam o Rio São Francisco por meio dos afluentes do Reservatório de Três Marias são a mineração, a agricultura e a ocupação urbana, onde os principais poluentes advém de metais, pesticidas e excesso de nutrientes (Almeida, 2010). Embora existam atividades potencialmente impactantes em seu entorno, o reservatório possui ambiente com características de águas claras (Curtarelli, 2020), sendo considerado de águas complexas do caso 2, fatores que dificultam a caracterização óptica do ambiente tendo em vista a variação espacial irregular dos COAs (Ferreira, 2014).

A qualidade da água do Reservatório de Três Marias é monitorada pela CEMIG que avalia parâmetros físicos, químicos ou biológicos da água. As técnicas de amostragem, preservação e análise utilizadas seguem o Manual de Procedimentos de Coleta e Metodologias de Análise de Água ([CEMIG, 2009](#)) e o *Standard Methods of the Examination of Water and Wastewater* ([APHA, 2012](#)). As coletas das amostras são do tipo simples, de superfície, coletadas às margens ou no centro dos cursos d'água.

3.2 Aquisição dos dados limnológicos e de sensoriamento remoto

3.2.1 Planejamento amostral

Para a definição dos pontos amostrais, uma série de critérios foi considerada junto a uma equipe de especialistas em recursos hídricos, meio ambiente, análise espacial, estatística, comunicação social, biodiversidade e geotecnologias. A definição dos locais de amostragem exige o conhecimento do entorno considerando os potenciais pontos focais de contaminação das águas que podem ser identificados de acordo com o tipo de uso do solo ([Santos et al., 2001](#)). Os locais de amostragem foram selecionados a priori considerando uma série de fatores incluindo profundidade, afluentes, uso do solo nas áreas circundantes (presença de agricultura e áreas urbanas) e atividades de piscicultura.

Uma campanha de campo foi realizada entre os dias 11 e 14 de setembro de 2019 a fim de caracterizar e diagnosticar o entorno à área de estudo. A partir desta campanha foi produzido um mapa de uso e cobertura do solo que permitiu uma compreensão prévia acerca da dinâmica do reservatório. Com auxílio dos dados coletados neste primeiro momento, as demais campanhas de campo foram realizadas a fim de levantar diferentes pontos amostrais. A primeira campanha no reservatório, realizada em 04 de outubro de 2019, teve como objetivo obter uma primeira avaliação de vários parâmetros de qualidade da água no reservatório como um todo, ou seja, de forma a cobrir a maior área viável obtendo a maior variação possível desses parâmetros baseado apenas no conhecimento prévio. Para tanto, foram efetuadas coletas e medições com sonda em treze pontos de amostragem de dezoito diferentes parâmetros. Por meio destas coletas e medições de caráter preliminar foi possível definir o planejamento amostral que indicaria os principais pontos onde ocorreram a aquisição dos dados e as análises amostrais deste trabalho.

3.2.2 Aquisição dos dados limnológicos

Oito campanhas de campo no Reservatório de Três Marias entre os anos de 2019 e 2021 contabilizando um total de 168 pontos amostrais. Buscando aprimorar o banco de dados, a base produzida por [Curtarelli \(2020\)](#), gentilmente cedida pelo INPE, foi incorporada às informações adquiridas em campo, totalizando 175 pontos. Outros parâmetros podem ter sido coletados ou medidos, mas foram omitidos aqui por não estarem diretamente relacionados ao trabalho. Os dados podem ser observados na Tabela 3.3. Cabe ressaltar que, como parte de um Projeto de P&D mais amplo, o critério para a

seleção dos pontos considerou as campanhas possíveis de serem realizadas no âmbito do projeto de acordo com a necessidade de toda a equipe envolvida.

Tabela 3.3: Campanhas de campo e parâmetros medidos/coletados entre os anos de 2019 e 2021.

Data	Nº de pontos	Parâmetro	Método
01 / jul / 2019*	07	Chl-a ($\mu\text{g/L}$)	Espectrofômetro
		Transparência (cm)	Disco de Secchi
04 / out / 2019	13	Chl-a, -b, -c ($\mu\text{g/L}$)	Análise de laboratório
		Turbidez (FNU)	Turbidímetro Lab1000
		Transparência (cm)	Disco de Secchi
		Temperatura ($^{\circ}$)	Oxímetro HACH (HQ430D)
		OD (mg/L)	Sonda Hanna (HI98194)
		pH	Sonda Hanna (HI98194)
		Condutividade (mV)	Sonda Hanna (HI98194)
		ORP (mV)	Sonda Hanna (HI98194)
		CT (mg/L)	Análise de laboratório
		COT (mg/L)	Análise de laboratório
		NT (mg/L)	Análise de laboratório
		FT (mg/L)	Análise de laboratório
		Clorato (mg/L)	Análise de laboratório
31 / mai / 2020	13	Sulfato (mg/L)	Análise de laboratório
		Ferro Total (mg/L)	Análise de laboratório
		SDT (mg/L)	Análise de laboratório
06 / mai / 2021	30	Chl-a ($\mu\text{g/L}$)	Sonda EXO2 (YSI)
		Turbidez (FNU)	Sonda EXO2 (YSI)
		Transparência (cm)	Disco de Secchi
20 / jun / 2021	22	Chl-a ($\mu\text{g/L}$)	Sonda EXO2 (YSI)
		Turbidez (FNU)	Sonda EXO2 (YSI)
		Transparência (cm)	Disco de Secchi
24 / ago / 2021	29	Chl-a ($\mu\text{g/L}$)	Sonda EXO2 (YSI)
		Turbidez (FNU)	Sonda EXO2 (YSI)
		Transparência (cm)	Disco de Secchi
23 / set / 2021	26	Chl-a ($\mu\text{g/L}$)	Sonda EXO2 (YSI)
		Turbidez (FNU)	Sonda EXO2 (YSI)
		Transparência (cm)	Disco de Secchi
28 / out / 2021	35	Chl-a ($\mu\text{g/L}$)	Sonda EXO2 (YSI)
		Turbidez (FNU)	Sonda EXO2 (YSI)
		Transparência (cm)	Disco de Secchi

*Fonte: [Curtarelli \(2020\)](#).

A primeira amostragem da água ocorreu no dia 04 de outubro de 2019 entre 08:00h e 14:00h tomando-se o devido cuidado para realiza-la no menor tempo possível a fim de reduzir possíveis

alterações nas propriedades da água. Foi utilizada uma embarcação a motor (Figura 3.3) que percorreu cerca de 85 km no eixo principal do reservatório. O deslocamento ocorreu no sentido de jusante (próximo à barragem) à montante do Reservatório de Três Marias até a confluência entre o braço principal do Rio São Francisco e o braço secundário do Rio Paraopeba.



Figura 3.3: Embarcação utilizada para a amostragem limnológica na represa.

A avaliação dos parâmetros físico-químicos de qualidade da água se efetuou por meio da utilização de sonda multiparâmetros e outros instrumentos específicos. O instrumento sensor foi acoplado à sonda Hanna (HI98194) e as medições foram realizadas em subsuperfície (aproximadamente 30 cm). Nesta campanha foram coletadas amostras em 13 pontos que apresentam diferentes características ao longo do reservatório onde foi possível mensurar *in situ* os seguintes parâmetros: OD, pH, transparência, temperatura, turbidez, condutividade e ORP. A transparência da água foi medida com o auxílio de um disco de Secchi, a temperatura foi determinada com o auxílio de um oxímetro HACH – HQ430D e, para mensuração de turbidez, utilizou-se um turbidímetro portátil Lab1000 – TB 1000. Os demais parâmetros, obtidos em laboratório, foram: chl-a, -b, -c, carbono total, carbono orgânico total, nitrogênio total, fósforo total, clorato, sulfato, ferro total e sólidos totais.

Para as análises de laboratório, cerca de 9 litros de água foram coletados em cada ponto amostral. Esta primeira avaliação, que incluiu parâmetros NOA, foi realizada com a finalidade de compreender a dinâmica do reservatório e obter uma primeira impressão sobre a qualidade da água do ambiente. As amostras foram acondicionadas em frascarias (algumas delas com conservantes apropriados) e armazenadas em isopor com gelo. Para a chl-a, as amostras foram, primeiramente, filtradas em campo e posteriormente acondicionadas em frascaria adequada.

Dadas as características dos componentes encontradas nos pontos levantados preliminarmente, quatro pontos de atenção foram identificados para a cobertura nas próximas campanhas, de maneira a representar compartimentos do reservatório com influência do entorno. O primeiro ponto localiza-se

próximo ao barramento, na cidade de Três Marias. Nas proximidades da barragem observou-se a maior clareza, transparência e qualidade da água. O segundo ponto está situado na cidade de Morada Nova. Próximo a esta estação estão localizadas diversas propriedades rurais, além de pivôs centrais. Junto ao terceiro ponto, localizado na divisa dos municípios de Morada Nova e Três Marias, estão presentes diversas atividades de piscicultura e inseridos numerosos tanques-rede. O quarto ponto está localizado no encontro dos rios São Francisco e Paraopeba, à montante do reservatório. Além da cobertura destas estações, outros pontos distribuídos ao longo do reservatório foram compreendidos nas demais campanhas de forma a tornar o banco de dados mais robusto. A Figura 3.4 apresenta a distribuição dos pontos amostrais de acordo com as campanhas realizadas.

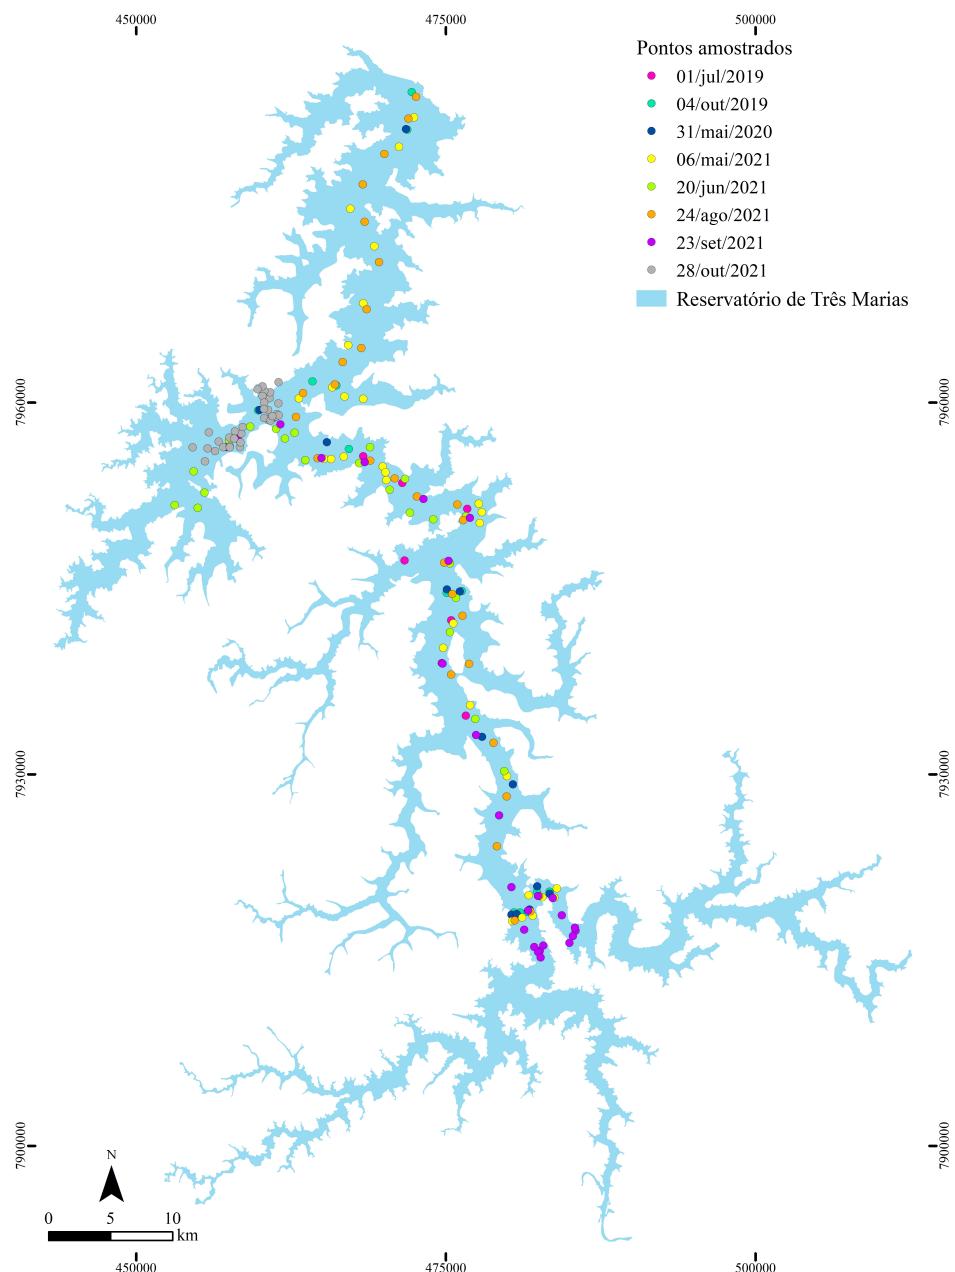


Figura 3.4: Distribuição dos pontos amostrais por campanha.

3.2.3 Aquisição dos dados de sensoriamento remoto

O sensor MSI a bordo dos satélites Sentinel-2 (A/B) é um espetrômetro imageador de observação da Terra lançado pela ESA nos anos de 2015 (2A) e 2017 (2B). Seu objetivo principal é monitorar as ocorrências variáveis e mudanças na superfície terrestre. Entre as suas principais características estão a disponibilidade de dados gratuitos, presença de 13 faixas espectrais, largura espectral da faixa de 290 km, além da alta frequência de revisita de cinco dias na região da represa ([ESA, 2021](#)). A Tabela 3.4 apresenta as características das bandas espectrais presentes no sensor MSI.

Tabela 3.4: Descrição das bandas espectrais do sensor MSI/Sentinel-2.

Banda espectral	Centro da banda (nm)	Comprimento de onda (nm)	Largura da banda (nm)	Resolução espacial (m)
B1. <i>Coastal</i>	443	421 – 457	36	60
B2. Azul	494	439 – 535	96	10
B3. Verde	560	537 – 582	45	10
B4. Vermelho	665	646 – 685	39	10
B5. <i>Vegetation Red-Edge</i>	704	694 – 714	20	20
B6. <i>Vegetation Red-Edge</i>	740	731 – 749	18	20
B7. <i>Vegetation Red-Edge</i>	781	768 – 796	28	20
B8. NIR	834	767 – 908	141	10
B8A. NIR	864	848 – 881	33	20
B9. Vapor d'água	944	931 – 958	27	60
B10. Cirrus	1375	1338 – 1414	76	60
B11. SWIR	1612	1539 – 1681	142	20
B12. SWIR	2194	2072 – 2312	240	20

A [ESA \(2021\)](#) disponibiliza os produtos provenientes do sensor MSI em três diferentes níveis de processamento:

1. NÍVEL-0: processamento realizado em tempo real, sincronizado de acordo com a entrada de dados captados pelo sensor;
2. NÍVEL-1: processamento que utiliza as informações do Nível-0 como dados de entrada. É subdividido em Nível-1A (descompactação), Nível-1B (corrigido radiometricamente) e Nível-1C (corrigido radiometricamente e geometricamente para a parte superior da atmosfera (*Top-of-Atmosphere* – TOA), incluindo ortorretificação e registro);
3. NÍVEL-2: processamento em Nível-2 (ou 2A) utiliza informações do Nível-1C para aplicar correção atmosférica para o fundo da atmosfera (*Bottom-of-Atmosphere* – BOA) (por padrão, a ESA utiliza o algoritmo Sen2Cor), além de apresentar classificação de cena.

Os produtos de Nível-0, 1A e 1B são processados internamente e não são disponíveis aos usuários. Esta pesquisa utilizou informações multiespectrais provenientes da missão de observação da Terra Sentinel-2/MSI em Nível-2A. As imagens de Nível-1C foram adquiridas gratuitamente por meio do

website PEPS (*Plateforme d'Exploitation des Produits Sentinel*) do CNES (*Centre National d'Études Spatiales*). A área de estudo está incluída na cena do Sentinel-2/MSI que corresponde à zona UTM 23 Sul, latitude K, faixa MV (23KMV).

Optou-se por realizar as campanhas de forma coincidente à passagem do satélite Sentinel-2. Em todas as datas, o sobrevoo do Sentinel-2 efetuou-se às 10:17 AM diferenciando-se, entre datas, por segundos. O planejamento dos campos realizou-se, principalmente, de forma a possibilitar a sincronia entre a coleta dos dados *in situ* e a passagem do satélite. As imagens correspondentes aos períodos possuíam cobertura irrigária de nuvens acima do espelho d'água (abaixo de 5%) além de não haver interferências atmosféricas identificáveis.

3.3 Processamento dos dados

3.3.1 Processamento dos dados limnológicos

Na primeira campanha limnológica, de 04 de outubro de 2019, as coletas foram realizadas com o auxílio de frascos e galões em polietileno onde as amostras foram devidamente armazenadas em caixas térmicas. Este procedimento visou preservar as amostras até a chegada ao laboratório, observando os tempos de coleta, onde seriam feitas as análises. No laboratório, as amostras foram armazenadas em congeladores até que o processamento fosse realizado. As análises das amostras de água foram efetuadas no Laboratório de Processos Oxidativos Avançados do Departamento de Engenharia Sanitária e Ambiental (DESA) da UFMG. As concentrações foram determinadas de acordo com os procedimentos descritos no *Standard methods for the examination of water and wastewater* (APHA, 2012).

As concentrações de clorofila (-a, -b, -c) foram obtidas por meio da extração em etanol e leitura em espectrofotômetro. Para as análises de CT, COT e NT utilizou-se o instrumento TOC-VCPN (*Total Organic Carbon Analyser – Shimadzu*). As amostras analisadas foram filtradas em membranas de nitrato de celulose (45 µm) e os resultados reportados como COD. A análise de SDT e sulfato foi determinada por método gravimétrico. Para fósforo total utilizou-se método colorimétrico, quantificado em espectrofotômetro a 690 nm. A análise de clorato utilizou-se o método *Mohr* colorimétrico. Ferro total foi analisado por meio de espetrometria de absorção atômica – plasma.

3.3.2 Processamento dos dados de sensoriamento remoto

A pesquisa utilizou os produtos de Nível-2A provenientes do satélite Sentinel-2/MSI. Dados de imagem de Nível-2 são pré-processados para incluir correções radiométricas e geométricas TOA e são fornecidos em forma de dados de reflectância espectral BOA. Dados de imagens de Nível-2A diferenciam-se de dados de Nível-1C devido a este pré-processamento a que as imagens são submetidas. Imagens de Nível-2 adquiridas com processamento para BOA são imagens já corrigidas de forma a amenizar os efeitos de espalhamento e absorção de gases atmosféricos e aerossóis. Esta correção visa reduzir ao mínimo qualquer interferência atmosférica presente na resposta espectral. Desta forma, o monitoramento da superfície terrestre pode ser efetuado de maneira mais assertiva.

As imagens do Sentinel-2 foram processadas por meio do *website* da PEPS que utiliza o algoritmo conjunto de pré-processamento MAJA (MACCS ATCOR Joint Algorithm, desenvolvido por [Lonjou et al. \(2016\)](#)) fornecido pelo CNES. As bandas do Sentinel-2 Nível-2 apresentam fator de escala de 0,0001, o que permite a conversão das bandas para reflectância por álgebra simples.

Uma vez que a área de pesquisa se restringe ao Reservatório de Três Marias, os pixels correspondentes às porções de terra foram excluídos do estudo, limitando a análise ao espelho d'água da represa. Para tanto, os pixels de água foram extraídos das imagens de satélite por meio do Índice de Diferença Normalizada da Água (NDWI), proposto por [McFeeters \(1996\)](#). Este índice utiliza uma banda do verde e uma banda do NIR, se configurando de acordo com a Equação 3.1:

$$NDWI = \frac{[\rho(\text{verde}) - \rho(\text{NIR})]}{[\rho(\text{verde}) + \rho(\text{NIR})]} \quad (3.1)$$

Este índice varia entre -1 e 1 e tem como limite o valor zero (0). Valores abaixo de 0 são classificados como “não água” e valores acima de 0 são classes relativas à água. Este índice permite maximizar a reflectância da água a partir da banda verde, minimizar a baixa reflectância da água no NIR e destacar o contraste terra/água que a banda infravermelha viabiliza ([Pereira et al., 2016](#)).

A fim de simplificar a extração de dados espectrais para a construção dos modelos estatísticos, todas as bandas Sentinel-2 com resolução espacial de 10 m e 20 m foram utilizadas, padronizadas em pixels de 20 m de forma a torná-las compatíveis dentro do mesmo conjunto de dados.

3.4 Modelagem estatística dos parâmetros de qualidade da água

3.4.1 Modelos ópticos de estimativa dos parâmetros

A investigação das pesquisas desenvolvidas ao longo dos anos registradas na literatura científica permitiu a identificação de diferentes modelos para a estimativa dos parâmetros ópticos de qualidade da água em ambientes lênticos e semi-lênticos. Modelos que utilizam algoritmos e bandas espectrais variadas foram avaliados e testados no Reservatório de Três Marias (Tabela 3.5).

Com o intuito de facilitar a assimilação ao longo do texto, foram geradas nomenclaturas (ID) que serão utilizadas para a identificação dos modelos empregados aqui. Foram processados modelos selecionados da literatura internacional cujos corpos d'água dos respectivos estudos apresentaram menores índice de turbidez (para a seleção de modelos de turbidez), clareza (para seleção de modelos de SDD) e baixa concentração de chl-a (para seleção de modelos de chl-a). A escolha destes modelos se justifica em função das características do Reservatório de Três Marias e da semelhança entre os valores de cada componente e o corpo d'água da pesquisa (ao menos em parte do ambiente aquático). Buscou-se, além da associação de aspectos semelhantes àqueles do reservatório de estudo, a seleção de diferentes técnicas estatísticas para a estimativa dos parâmetros ópticos de qualidade da água:

- TURBIDEZ: Regressão Linear Simples (RLS), Regressão Linear Múltipla (RLM), Regressão Quadrática (RQ) e Razão de Bandas (RB), sendo uma delas o Índice de Turbidez por Diferença

Normalizada (*Normalized Difference Turbidity Index – NDTI*);

- SDD: RB e RLM;
- CHL-a: RB, sendo uma delas o Índice Máximo de Clorofila (*Maximum Chlorophyll Index – MCI*) e outra a Altura Máxima do Pico (*Maximum Peak-Height – MPH*).

Os modelos apresentados nas Tabelas 3.6, 3.7 e 3.8 foram adaptados de acordo com as bandas do sensor MSI/Sentinel-2.

Os modelos selecionados na Tabela 3.5 são referentes à corpos d'água existentes em diversas regiões da superfície terrestre e fazem uso de diferentes sensores ópticos acoplados à satélites cuja distribuição dos produtos incorre de maneira gratuita. A eficácia de tais modelos foi comprovada para os estudos *in situ* e, portanto, serão exportados para o Reservatório de Três Marias para validação do desempenho de cada um.

3.4.2 Modelos de regressão

Antes de realizar as regressões, foi necessário extrair os valores de reflectância espectral das bandas das imagens de satélite correspondentes aos pontos de coleta. A busca da informação ocorre a partir do ponto de coordenada e da data da amostragem. Em todas as campanhas, os valores de cada pixel foram adotados para análise estatística e consolidados em uma planilha contendo os valores mensurados pelas sondas multiparâmetros.

Entre as abordagens empíricas de modelos de qualidade da água usando sensoriamento remoto, correlação, regressões lineares simples e regressões lineares múltiplas são seguramente as técnicas inferenciais mais utilizadas. Neste caso, regressões lineares simples foram realizadas com o auxílio do software RStudio (v. 1.5.5109) para analisar a relação entre alguns dos parâmetros de qualidade da água e os valores de reflectância do núcleo de análise. Nesta fase foi adotada uma abordagem completamente empírica que pode produzir modelos com grande robustez (Matthews, 2011). A seleção de preditores foi realizada usando duas abordagens diferentes:

1. a priori, a seleção de preditores baseados nas bandas espectrais do sensor MSI foi realizada usando como abordagem um método de regressão denominado *Knock-out* (Sambur, 1975) que consiste na seleção do melhor conjunto de preditores por iteração, considerando que o mérito relativo da variável selecionada é baseada na própria contribuição para o desempenho do modelo. O método adotado utiliza um processo sequencial de formação de subconjuntos onde são testados grupos de variáveis. O objetivo do processo de seleção é eliminar variáveis que não contribuem significativamente na determinação do parâmetro de qualidade da água. Sambur (1975) explica que, caso um dado grupo de variáveis G demonstre menor erro entre outros grupos, G será considerado o melhor subconjunto de dados entre os demais. Cada subconjunto tem sua eficácia avaliada considerando um número N de variáveis menos 1 (N - 1). O subconjunto que apresentar o melhor resultado tem a variável que foi desconsiderada eliminada e o processo é repetido até que o melhor subconjunto seja revelado (Figura 3.5). Esta etapa foi aplicada a todos os parâmetros levantados *in situ*;

Tabela 3.5: Equações referentes aos modelos para estimativa de turbidez, SDD e chl-a baseadas nas bandas espectrais do sensor MSI.

ID	Modelo	Técnica	Referência
$Turb_1$	$(\rho_{B2} + \rho_{B8}) * \rho_{B8}$	RLS	Wang <i>et al.</i> (2021)
$Turb_2$	$\alpha + \beta_1\rho B2 + \beta_2\rho B3 + \beta_3\rho B4 + \beta_4\rho B8$	RLM	Kapalanga <i>et al.</i> (2021)
$Turb_3$	$(\rho B5 - \rho B11) + \left(\frac{\rho B2}{\rho B12} \right)$	RLM	Torres-Bejarano <i>et al.</i> (2021)
$Turb_4$	$\frac{(\rho B8 * \rho B4)}{\rho B3}$	RQ	Abdelmalik (2018)
$Turb_5$	$NDTI = \frac{\rho B4 - \rho B3}{\rho B4 + \rho B3}$	RB	Lacaux <i>et al.</i> (2007)
$Turb_6$	$\frac{\rho B4}{\rho B2}$	RB	Cox Jr <i>et al.</i> (1998)
SDD_1	$\frac{\rho B2}{\rho B5}$	RB	Sòria-Perpinyà <i>et al.</i> (2020)
SDD_2	$\left[\frac{(\rho B2 + \rho B8)}{\rho B4} \right]^{2,29}$	RB	Li <i>et al.</i> (2020)
SDD_3	$\frac{\rho B4}{\rho B3}$	RB	Avdan <i>et al.</i> (2019)
SDD_4	$-8,753 * \left(\frac{\rho B8}{\rho B2} \right) + 5,223 * \frac{\rho B8}{\rho B8 + 2,552}$	RLM	Xu <i>et al.</i> (2018)
SDD_5	$1,806 * \frac{\rho B2}{\rho B4} - 0,8903$	RB	Kallio <i>et al.</i> (2008)
$Chla_1$	$\frac{\rho B4}{\rho B8}$	RB	Flores-Anderson <i>et al.</i> (2020)
$Chla_2$	$\frac{\rho B2}{\rho B3}$	RB	Flores-Anderson <i>et al.</i> (2020)
$Chla_3$	$MCI = B5 - 1,005 + [B4 + \frac{(B6 - B4) * (\rho B5 - \rho B4)}{\rho B6 - \rho B4}]$	RB	Peppa <i>et al.</i> (2020)
$Chla_4$	$MPH = B5 - B4 + \frac{(B8A - B4) * (\rho B5 - \rho B4)}{\rho B8A - \rho B4}$	RB	Peppa <i>et al.</i> (2020)
$Chla_5$	$\frac{\rho B5}{\rho B4}$	RB	Ha <i>et al.</i> (2017)
$Chla_6$	$\frac{(\rho B5 + \rho B6)}{\rho B4}$	RB	Ha <i>et al.</i> (2017)
$Chla_7$	$\rho B5 - \frac{(\rho B4 + \rho B6)}{2}$	RB	Toming <i>et al.</i> (2016)

2. a segunda abordagem consistiu na combinação dos preditores amplamente utilizados, embasada em levantamento bibliográfico, tendo em vista a importância de cada banda para a identificação e caracterização de qualidade da água em diferentes estudos. Esta escolha objeti-

Tabela 3.6: Descrição das abordagens utilizadas para estimativa de turbidez nos estudos selecionados.

ID	Avaliação da performance	Satélite/Sensor	Turbidez local (NTU/FNU)	Corpo d'água	País
$Turb_1$	$r^2 = 0,89$ $p\text{-value} < 0,01$ $RMSE = 23,82$	L-5/TM L-7/ETM L-8/OLI	$\approx 0,05 - \approx 280,0$	Diversos lagos na cidade de Daqing	China
$Turb_2$	$r^2 = 0,76$	L-8/OLI	$5,97 - 54,97$	Barragem Olushandja	Namíbia
$Turb_3$	$r^2 = 0,87$ $p\text{-value} < 0,01$ $RMSE = 1,66$	S-2/MSI	$1,18 - 18,61$	Complexo Bajo Sinú	Colômbia
$Turb_4$	$r^2 = 0,99$ $RMSE = 0,89$	Terra/ASTER	$1,01 - 85,0$	Lago Qaroun	Egito
$Turb_5$	—	SPOT-5/ HRVIR	$0 - 80 (\%)$	Sete lagos na região de Ferlo	Senegal
$Turb_6$	$r^2 = 0,86$	L-5/TM	$14,0 - 41,0$	Reservatórios do Rio Catawba	EUA

Tabela 3.7: Descrição das abordagens utilizadas para estimativa de SDD nos estudos selecionados.

ID	Avaliação da performance	Satélite/Sensor	Transparência (m)	Corpo d'água	País
SDD_1	$r^2 = 0,67$ $p\text{-value} < 0,01$ $RMSE = 7 \text{ cm}$	S-2/MSI	$0,19 - 0,62$	Albufera de Valênciam	Espanha
SDD_2	$r^2 = 0,79$ $RMSE = 9 \text{ cm}$	L-8/OLI	$\bar{x} 3,3 - \bar{x} 4,0$	Reservatório Xin'anjiang	China
SDD_3	$r^2 = 0,76$	RapidEye	$0,95 - 2,80$	Lago Borabey	Turquia
SDD_4	$r^2 = 0,86$ $p\text{-value} < 0,01$ $RMSE = 11,8 \text{ cm}$	L-8/OLI	$0,25 - 1,10$	Lago Liangzi	China
SDD_5	$r^2 = 0,69$ $RMSE = 38 \text{ cm}$	L-7/ETM+	$0,5 - 5,5$	Lagos meridionais	Finlândia

vou preservar os graus de liberdade refinando os resultados gerados pela regressão *Knock-out* e garantindo a presença destas importantes variáveis na análise estatística ([Babyak, 2004](#)).

A adoção desta dupla estratégia teve por finalidade reduzir o número de variáveis preditoras do modelo tornando-o mais objetivo, mais significativo e evitando um possível *overfitting*.

O uso de dados espectrais calibrados por satélite transformados em reflectância BOA otimizou significativamente a capacidade de construir modelos inferenciais mais robustos. Ainda assim, outros fatores dificultam a aplicação de modelos de qualidade da água para outros ambientes ou mesmo outros períodos da mesma região. Mesmo com algoritmos avançados de correção atmosférica os

Tabela 3.8: Descrição das abordagens utilizadas para estimativa de chl-a nos estudos selecionados.

ID	Avaliação da performance	Satélite/Sensor	Chl-a local ($\mu\text{g/L}$)	Corpo d'água	País
<i>Chla₁</i>	$r^2 = < 0,30$	EO-1/Hyperion	1,01 – 10,91	Lago Atitlán	Guatemala
<i>Chla₂</i>	$r^2 = < 0,30$	EO-1/Hyperion	1,01 – 10,91	Lago Atitlán	Guatemala
<i>Chla₃</i>	$r = > 0,95$	S-2/MSI	0 – 257,0	Lago Pamvotis	Grécia
<i>Chla₄</i>	$r = > 0,95$	S-2/MSI	0 – 257,0	Lago Pamvotis	Grécia
<i>Chla₅</i>	$r^2 = 0,29$	S-2/MSI	1,58 – 23,2	Lago Ba Be	Vietnã
<i>Chla₆</i>	$r^2 = 0,18$	S-2/MSI	1,58 – 23,2	Lago Ba Be	Vietnã
<i>Chla₇</i>	$r^2 = 0,80$	S-2/MSI	3,60 – 72,9	Onze lagos	Estônia

modelos são altamente sensíveis a pequenos erros que essas estimativas produzem (Matthews, 2011). Outros problemas incluem a não linearidade que impede que os modelos funcionem bem fora do intervalo para o qual foram criados e a co-variação de dois ou mais parâmetros de qualidade da água que produzem soluções não únicas, como quando a turbidez e o chl-a variam independentemente um do outro mas produzem uma única resposta óptica. Esses parâmetros também podem ser vistos como a simplificação de uma situação mais complexa. Como exemplo, a concentração igual de sedimentos suspensos de origem diferente (como argila e silte) pode produzir uma resposta espectral diferente do esperado.

Considerando essas dificuldades, a abordagem foi projetada de forma a garantir a minimização de seus efeitos por meio dos seguintes critérios:

1. Simplificação dos modelos, mantendo uma alta eficiência (coeficiente de determinação);
2. Avaliação de bandas espectrais do sensor MSI e feições derivadas da literatura;
3. Uso de algoritmo de seleção de recursos (*Knock-out*);
4. Comparação de modelos construídos a partir de diferentes ambientes;
5. Construção e calibração de modelos genéricos para ajuste de todos os conjuntos de dados *in situ* e;
6. Realização de validação cruzada com outro reservatório com características semelhantes.

Simplificar os modelos significa o uso mínimo de atributos possíveis mantendo alto coeficiente de determinação, mas também significa tentar manter os mesmos atributos selecionados ao longo de todas as pesquisas. O objetivo é priorizar as feições (faixas espectrais, razões de banda ou índices) que são comuns ao maior número de modelos individuais produzidos a partir de cada dado de campanha de campo *in situ*. Todos os modelos foram comparados em termos de desempenho, aplicando-os a imagens Sentinel-2 de outras datas diferentes para as quais havia dados *in situ*, e avaliados por meio de medições de erro.

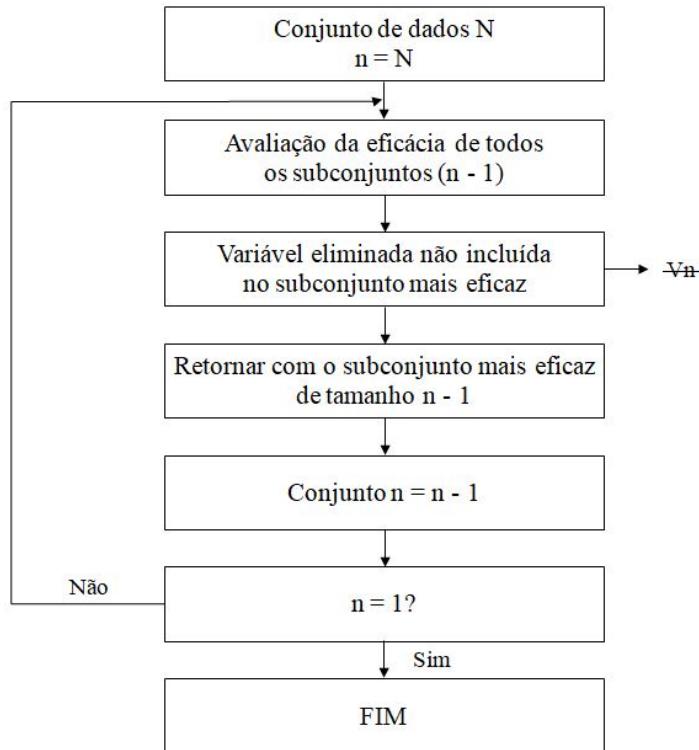


Figura 3.5: Método *Knock-out* para seleção de variáveis.

Fonte: [Sambur \(1975\)](#).

Um modelo dito “genérico” foi construído na tentativa de prever os parâmetros de qualidade da água superficial em qualquer imagem do Reservatório de Três Marias e, possivelmente, outros reservatórios com características semelhantes. O modelo genérico foi criado usando todos os pontos de pesquisa *in situ*, independentemente da data de aquisição, criando um conjunto de dados de pacote que inclui valores de reflectância extraídos de suas respectivas imagens. O modelo genérico foi avaliado por sua capacidade de predizer os parâmetros com precisão aceitável.

Ao final da construção e seleção do modelo para cada parâmetro realizou-se a calibração dos algoritmos por meio de um procedimento operacional com base em dois pontos específicos do reservatório: um ponto a jusante (onde os valores dos parâmetros costumam ser menos elevados, se comparados aos demais) e um ponto a montante (próximo à confluência entre os rios São Francisco e Paraopeba, que abastecem o reservatório). Para tanto, utilizou-se o *software* livre [SIMOA SAT](#). A ferramenta permitiu construir os índices de turbidez, transparência e concentração de chl-a por campanha de forma a selecionar manualmente os pontos amostrados de acordo com a data. O uso desse procedimento pode tornar esses modelos e índices muito mais confiáveis e reduzir significativamente seus erros.

3.4.3 Validação dos modelos e avaliação da acurácia

Foram aplicadas métricas estatísticas com a finalidade de descrever a diferença entre os dados previstos e adquiridos, além de avaliar a performance dos modelos. As métricas aplicadas foram: Coeficiente de Determinação (r^2 – Equação 3.2), Erro Médio Absoluto (MAE – Equação 3.3) e Raiz do Erro Médio Quadrático (RMSE – Equação 3.4).

$$r^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n | \hat{y}_i - y_i | \quad (3.3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3.4)$$

onde:

N = número de amostras;

p = número de variáveis (ou dados de entrada do modelo);

\hat{y} = valor predito;

\bar{y} = valor médio das amostras e;

y = valor real.

O r^2 fornece uma estimativa da proporção da variância explicada pelo modelo. Este coeficiente apenas é um estimador válido caso sua significância seja alta. Para esta pesquisa, foi utilizado um nível de significância de 95% ($p < 0,05$). O MAE indica a distância vertical média entre o valor previsto e o valor observado. O RMSE é, normalmente, usado para avaliar modelos, porém é bastante sensível a *outliers*.

Após a aplicação das métricas estatísticas, os modelos de regressão foram empregados às bandas dos satélites correspondentes por meio de álgebra de mapas a fim de validar as respostas preditas com os dados amostrados *in situ*. A validação foi realizada para cada data de pesquisa, bem como para o conjunto de dados do pacote contendo todos os dados adquiridos. Além disso, um levantamento de outro reservatório (Várzea das Flores) foi usado para validar a abordagem.

Capítulo 4

RESULTADOS E DISCUSSÃO

4.1 Qualidade da água do Reservatório de Três Marias

ANÁLISES do último Relatório de Impacto Ambiental viabilizado pela CEMIG (2019) indicam que a qualidade da água do Reservatório de Três Marias e alguns de seus afluentes apresentam, de modo geral, boa condição de acordo com o Índice de Qualidade das Águas calculado conforme monitoramentos efetuados. No entanto, há pontos do reservatório em que foram registrados índices excelentes de qualidade da água e outros onde o registro da qualidade da água variou entre as condições média a ruim. Cabe ressaltar que as principais alterações em que observaram-se as piores condições da água foram identificadas fora do limite da represa: ao longo do Rio São Francisco, antes e após o reservatório, e no Rio Abaeté, afluente do Rio São Francisco que deságua após a barragem de Três Marias. Dentro do reservatório os resultados demonstraram boa qualidade da água (BRANDT Meio Ambiente, 2019).

A primeira campanha permitiu reconhecer preliminarmente o ambiente aquático de estudo. Os resultados dos pontos de amostragem obtidos tanto *in situ* quanto no laboratório pós-campanha podem ser observados nas Tabelas Complementares 3 e 4. Das dez variáveis apresentadas nessas tabelas, apenas quatro são consideradas opticamente ativas (Tabela 3).

A análise dos 13 pontos de amostragem coletados no reservatório revela uma diminuição da qualidade da água na direção de jusante à montante. Em particular, a confluência entre os rios São Francisco e Paraopeba mostram-se consideravelmente mais turvos do que os demais pontos. Os dois pontos localizados no vetor Norte do reservatório (1 e 2) apontam uma transparência do disco de Secchi de, aproximadamente, 6 m e turbidez de 0,2 FNU.

Um ponto importante a ser associado à qualidade de água observada no Reservatório de Três Marias é o uso das áreas ao entorno (Figura 4.1). Como observado no campo exploratório (setembro de 2019) os empreendimentos identificados no entorno do reservatório foram, em sua maioria, atividades agrossilvipastoris (manejo de gado, florestas de eucalipto e plantações irrigadas por pivôs centrais). Outro aspecto importante foi a constatação de atividades de cultivo de espécies de peixes (piscicultura) em tanques ou tanques-rede. Se conduzida de forma desordenada, esta prática, mesmo que contribua para o desenvolvimento socioeconômico da região, pode afetar o ecossistema aquático

no qual está inserida pois leva à inserção de nutrientes para o cultivo dos peixes favorecendo o processo de eutrofização. A ocorrência de tanques de piscicultura justifica os valores encontrados para chl-a nos pontos 6, 7 e 8, os quais estão inseridos em regiões próximas a esses tipos de atividades. De acordo com o IGAM, considerando apenas a chl-a identificada na data da coleta, estes valores não indicam, neste momento, estado de eutrofização do reservatório. No entanto, deve-se mencionar que essas medições foram feitas durante a estação seca, quando a qualidade da água tende a ser melhor.

Os pontos 7 e 8 localizam-se na extremidade norte de uma pequena comunidade, denominada Ilha do Mangabal, e apresentam um leve aumento da turbidez e da concentração de chl-a, comparados aos demais (com exceção do Ponto 6). Próximo a estes pontos foram observadas colônias de algas e/ou cianobactérias, como ilustra a Figura 4.2. Embora ainda não seja considerada uma floração, este fato reafirma a necessidade do monitoramento contínuo, especialmente de parâmetros como chl-a, fósforo e nitrogênio (carga de nutrientes), que podem contribuir para uma futura eutrofização do reservatório além de alteração do ecossistema local de modo significativo (Barbosa *et al.*, 2019).

Nota-se o aumento da turbidez ao longo do caminho percorrido, do barramento à entrada dos rios contribuintes, São Francisco (Pontos 9, 10 e 11) e Paraopeba (Pontos 12 e 13), que são rios advindos de regiões mais antropizadas e que receberam maiores cargas de matérias orgânicas e inorgânicas em relação a área do barramento. Em concordância, os dados coletados para a profundidade do disco de Secchi reduzem ao longo do percurso, uma vez que a profundidade de desaparecimento do disco de Secchi é inversamente proporcional à quantidade de compostos orgânicos e inorgânicos no caminho óptico (Esteves, 1998). Tal comportamento pode ser corroborado pela tendência do aumento do COT ao longo dos pontos, que pode atuar como um importante indicador do grau de poluição do meio aquático (Moore, 1998). Resultados preliminares já indicavam que há influência da qualidade da água de afluentes na qualidade da água do reservatório nos pontos localizados próximos à entrada do Paraopeba e Rio São Francisco (BRANDT Meio Ambiente, 2019). É importante destacar que, para esta coleta, não foi possível avaliar os dados de TSS uma vez que o volume amostrado de água no reservatório não garantiu confiabilidade da análise devido aos baixos valores que estavam próximos ao limite de quantificação do método.

Considerando os resultados referentes à primeira campanha de campo, outras seis campanhas foram realizadas no reservatório entre os anos de 2020 e 2021 (ver Apêndice 5.1). A partir da análise dos dados de qualidade da água dos 168 pontos amostrados somados aos 7 pontos cedidos pelo INPE (campanha de 01/07/2019), é possível observar baixa variação em todo o reservatório com relação aos valores dos parâmetros obtidos em subsuperfície (Tabela 4.1). Os valores de chl-a variaram entre 0,56 e 8,1 µg/L com média de 1,667 µg/L e apresentaram o maior coeficiente de variação (134,88%). Turbidez variou entre 0,20 e 6,27 FNU com média de 1,448 FNU e coeficiente de variação de 61,19%. A transparência medida pelo Disco de Secchi apresentou o menor coeficiente de variação (26,30%) e valores médios de 300,9 cm, variando entre 160 e 599 cm.

Os índices medidos são geralmente considerados bastante baixos e, por vezes, dificilmente mensuráveis por meio da sonda utilizada YSI EXO2. Embora essas águas sejam consideradas de qualidade relativamente boa para um reservatório, elas ainda necessitam de monitoramento. Considerando turbidez abaixo de 5 FNU (exceto em uma medição) e concentrações de chl-a entre 0,56 e 8,0 µg/L, as

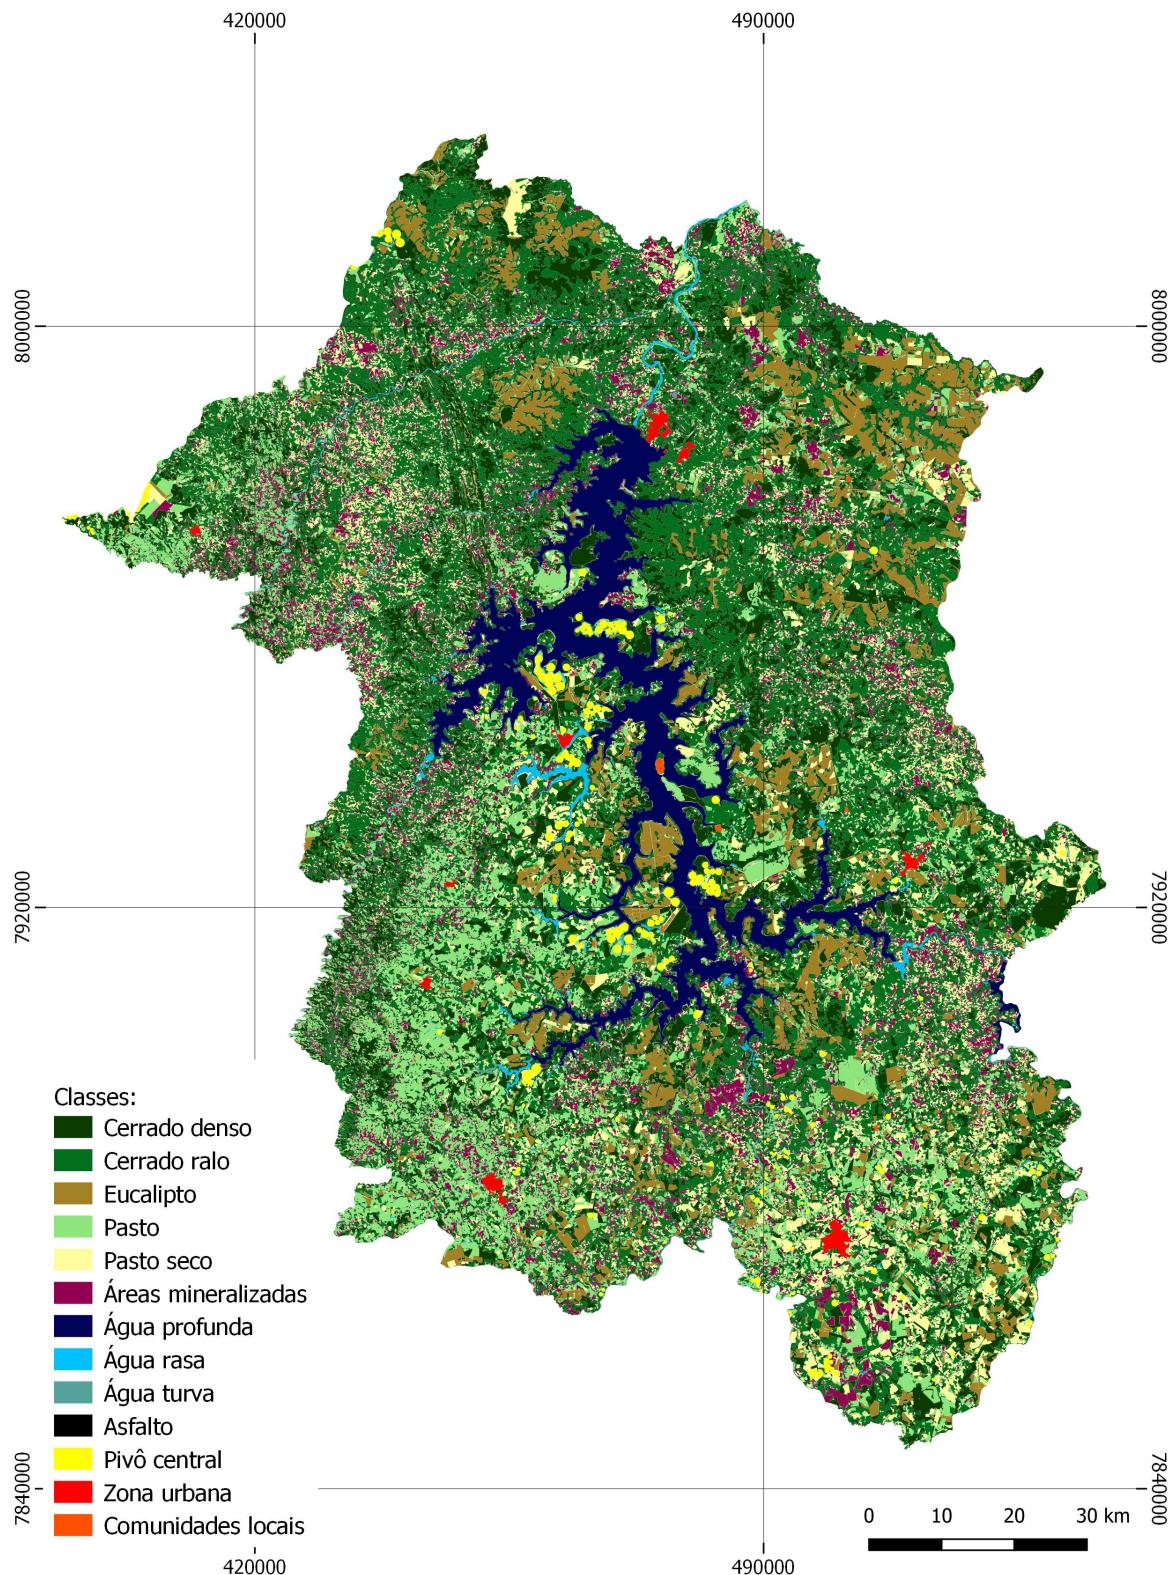


Figura 4.1: Classificação do uso e cobertura do solo do entorno do Reservatório de Três Marias.



Figura 4.2: Presença de algas/cianobactérias observada próximo aos pontos 7 e 8.

Tabela 4.1: Estatística descritiva dos resultados de qualidade da água no Reservatório de Três Marias.

Parâmetro	Mínimo	Máximo	Média	Mediana	Desvio Padrão	Coeficiente de Variação
Chl-a ($\mu\text{g/L}$)	0,56	8,10	1,667	1,305	2,262	134,88%
Turbidez (FNU)	0,20	6,27	1,448	1,310	0,886	61,19%
SDD (cm)	160	599	300,9	290,0	79,15	26,30%

água de Três Marias são consideradas, no máximo, de oligotróficas a mesotróficas (Canfield Jr *et al.*, 1983; Wetzel, 2001). Essas concentrações de chl-a, por exemplo, podem representar uma limitação, uma vez que a maioria dos estudos que usam produtos de sensoriamento remoto para estimar chl-a relata erros quadráticos médios superiores a $5,0 \mu\text{g/L}$. Por outro lado, muitos estudos foram capazes de mensurar os níveis de turbidez em faixas semelhantes.

A Figura 4.3 mostra claramente que o nível de água do reservatório variou significativamente entre os diferentes levantamentos. Esse fato é confirmado pelo gráfico do nível de água mostrado na Figura 4.4 que variou entre 560,22 m e 571,83 m. O gráfico mostra a resposta espectral de todos os pontos de pesquisa. Embora nem todos os meses estejam representados, aparentemente os meses de setembro e outubro apresentam a maior variação em comparação aos meses de maio a agosto (geralmente mais secos).

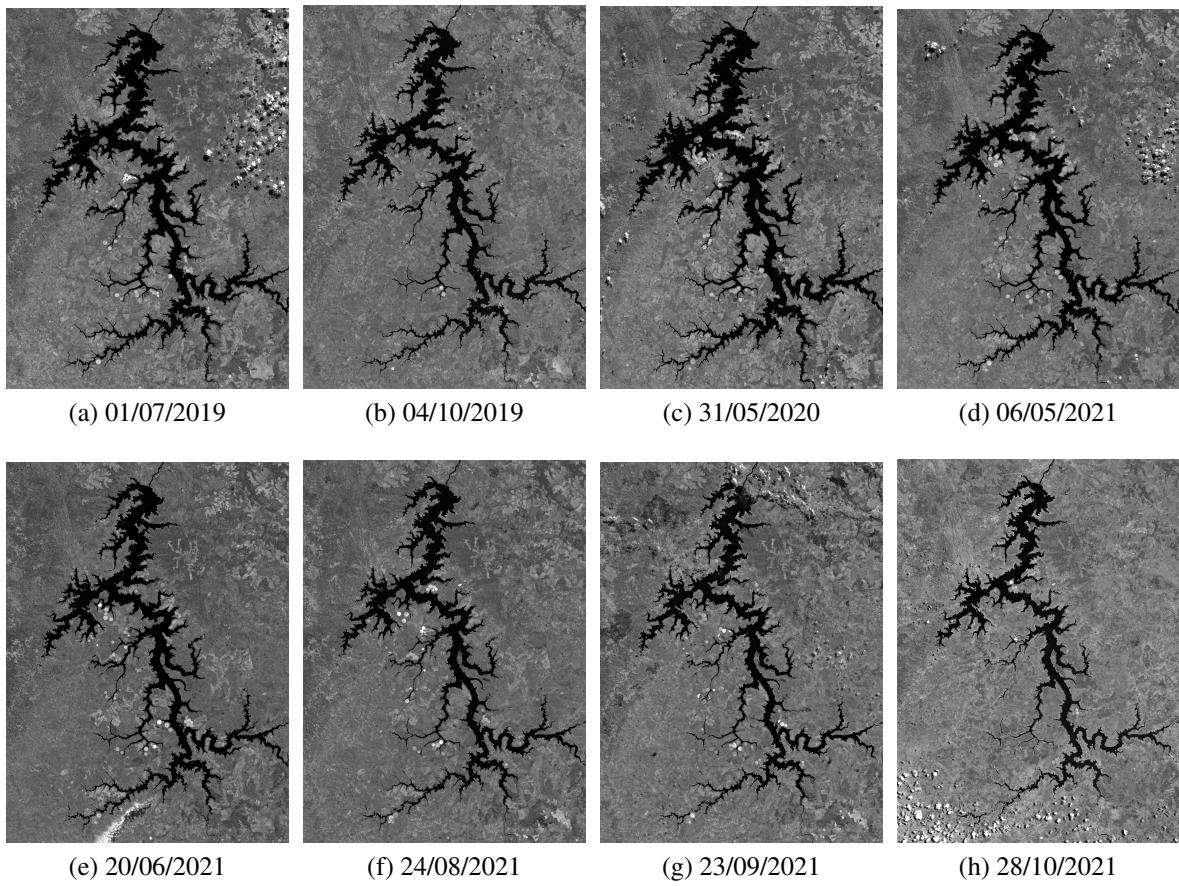


Figura 4.3: Subcenas das oito imagens do Sentinel-2 (banda 8A – NIR) mostrando a diferença entre os níveis d’água do reservatório nas oito campanhas de campo.

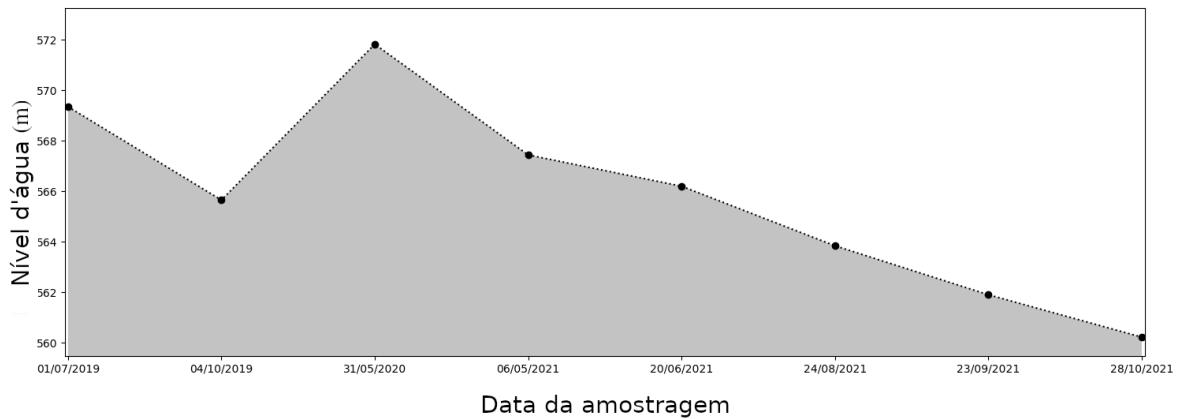


Figura 4.4: Gráfico mostrando o nível da água durante os oito levantamentos de campo no Reservatório de Três Marias.

4.2 Modelagem óptica dos parâmetros

O comportamento espectral da água do Reservatório de Três Marias nos pontos amostrados pode ser observado na Figura 4.5. Cada linha representa um ponto amostrado após correção atmosférica da imagem. Com base em todas as campanhas, foram constatados picos de reflectância, principalmente, na região do verde (≈ 560 nm). A presença de sedimentos em suspensão contribui com o aumento da reflectância nos comprimentos de onda menores ou iguais à região do vermelho. No Reservatório de Três Marias, observa-se o contrário: no geral, há um decréscimo da intensidade a medida que aumenta o comprimento de onda. Nas diversas tentativas de registro do total de sólidos em suspensão pela sonda EXO2, nenhuma campanha obteve valores passíveis de mensuração acima do limite de detecção. Uma variação discreta da intensidade do espectro pode ser observada nos comprimentos de onda do *red-edge* (≈ 783 nm) e do NIR (≈ 865 nm) nas campanhas de maio, agosto e setembro de 2021.

Verifica-se maior amplitude de variação nas campanhas realizadas no mês de outubro de 2019 e de 2021. O ponto com maior reflectância espectral entre todas as campanhas foi amostrado em outubro de 2021 atingindo $\approx 0,08\ sr^{-1}$. A menor amplitude foi observada na campanha de julho de 2019, realizada por [Curtarelli \(2020\)](#). Nesta ocasião, a variação de intensidade dos valores esteve entre 0 e $\approx 0,03\ sr^{-1}$, sendo o ponto de maior valor localizado próximo ao Porto Novo, em Morada Nova de Minas. É importante lembrar que os pontos amostrados nesta campanha concentram-se na parte central do reservatório (Figura 3.4).

A maior parte dos pontos que apresentam maior reflectância espectral estão localizados na região de confluência entre os rios Paraopeba e São Francisco. No entanto, houve uma excepcionalidade no registro efetuado na campanha de maio de 2019. O ponto com maior reflectância desta campanha, atingindo $0,075\ sr^{-1}$ no comprimento de onda do verde foi amostrado próximo à barragem do reservatório.

A água limpa manifesta reflectância espectral muito baixa, apresentando taxas em torno de 4% ([Novo et al., 2009](#)). Assume-se que a absorção de luz na região do infravermelho se aproxima de zero em águas pouco turvas ([Barbosa et al., 2019](#)). Os pontos amostrados nas diferentes épocas e em variadas regiões do reservatório não ultrapassaram o valor de 8% de reflectância espectral, o que reforça a característica de um reservatório como um ambiente de águas claras e moderadamente claras.

4.2.1 Turbidez

O *boxplot* na Figura 4.6 mostra o intervalo referente ao índice de turbidez obtido durante os levantamentos de campo realizados em sete campanhas. Em geral, os índices menos elevados de turbidez do Reservatório de Três Marias foram registrados próximo ao barramento. As duas últimas campanhas não mensuraram a turbidez nas proximidades da barragem. O índice mais alto corresponde ao valor de *outlier* foi registrado na campanha de maio de 2020 (6,27 FNU).

A campanha realizada em maio de 2020 apresentou valores de turbidez inesperados, onde os maiores valores foram encontrados nas proximidades da barragem do reservatório e os menores va-

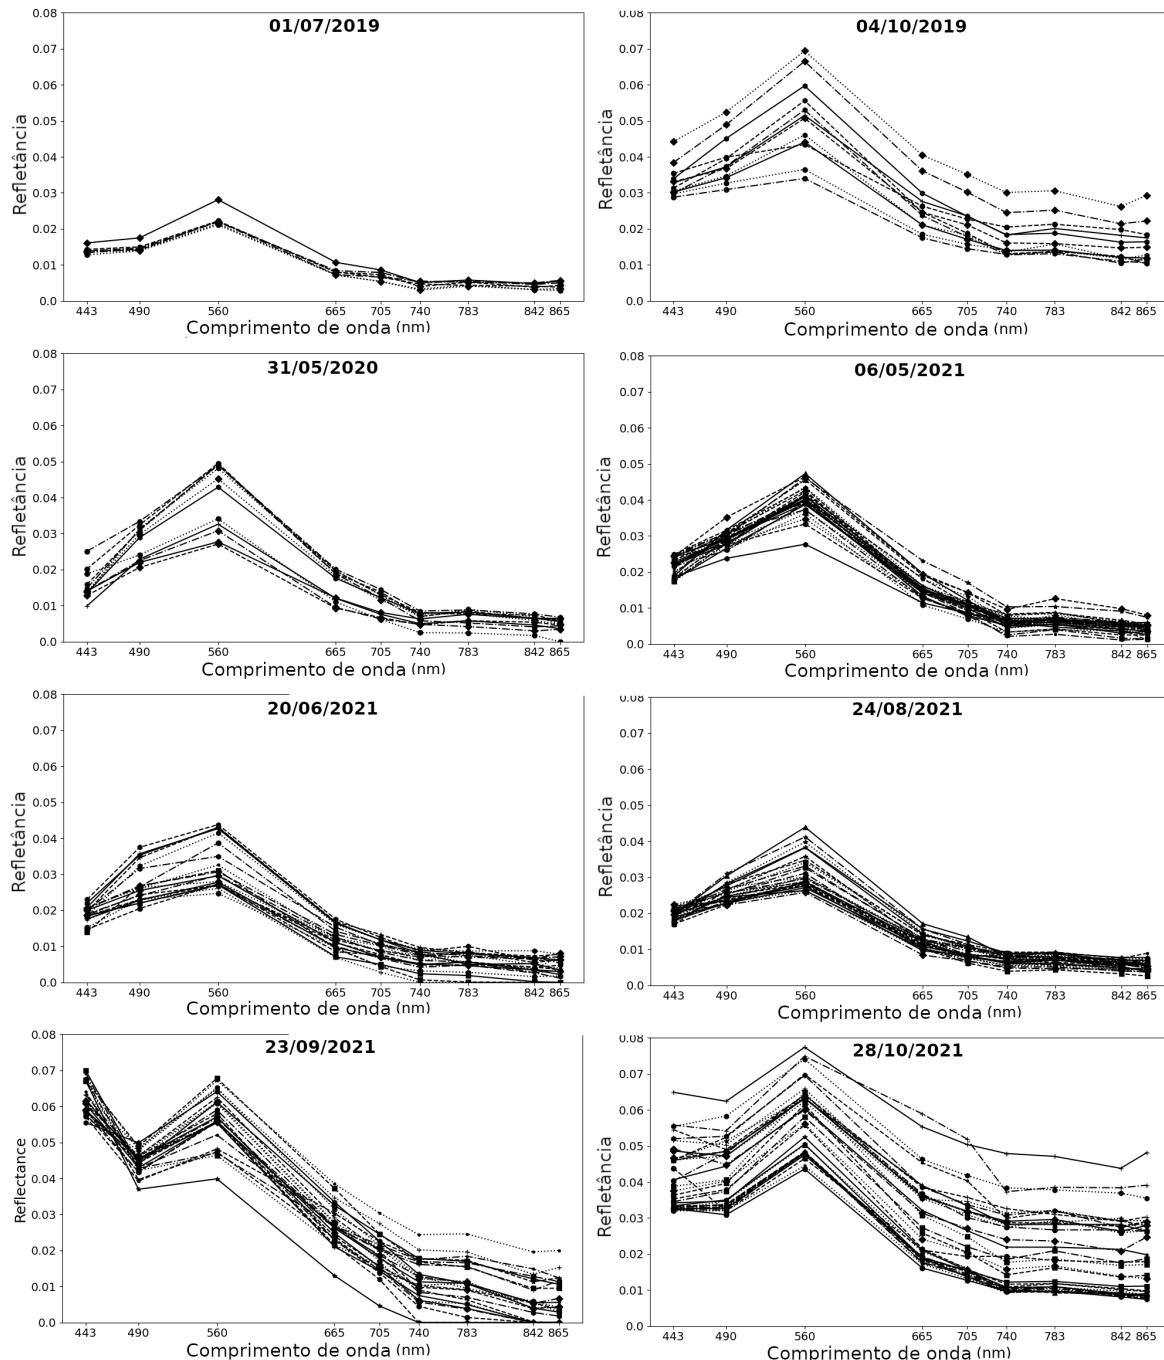


Figura 4.5: Comportamento espectral da água do Reservatório de Três Marias nos pontos mensurados durante as campanhas de campo.

lores obtidos a medida em que o barco se deslocava no sentido à montante. Sabe-se que uma série de fatores podem ter influenciado para que o comportamento do reservatório se diferisse das demais campanhas (como, por exemplo, revolvimento de fundo, estratificação e circulação natural da coluna d'água, manejo operacional da barragem, entre outros). Cabe ressaltar que esse comportamento singular foi registrado em um momento onde houve a necessidade de medidas de isolamento social

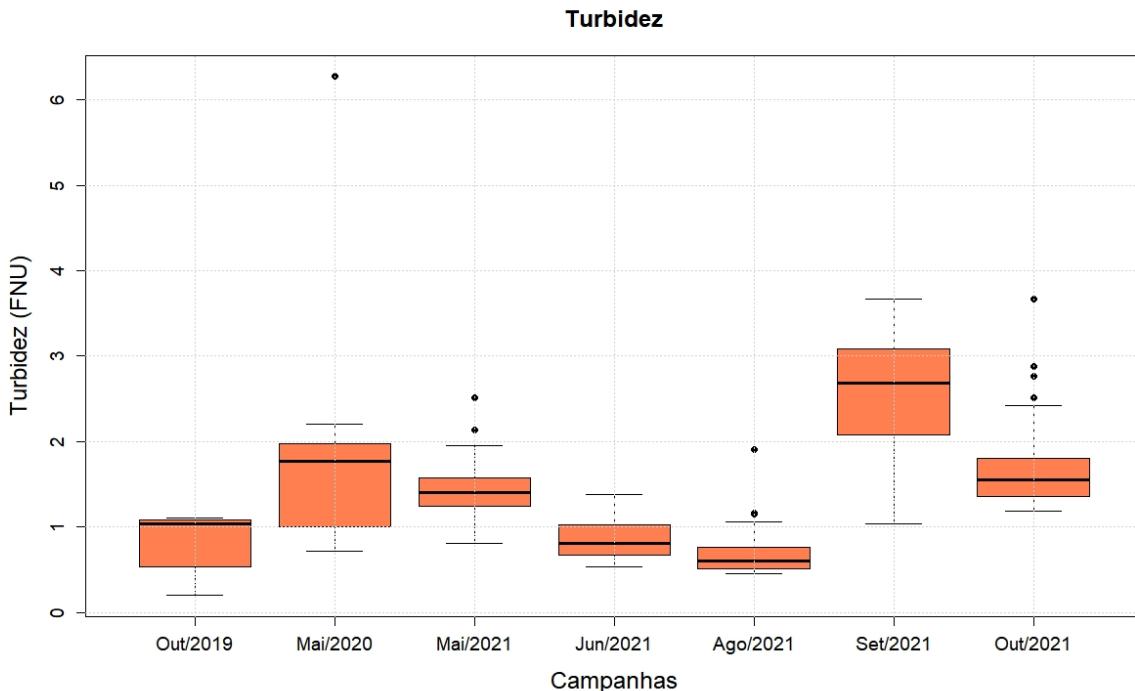


Figura 4.6: *Boxplot* da turbidez para as campanhas de campo.

em decorrência do surgimento da COVID-19. Neste período, o reservatório encontrava-se subutilizado, uma vez que atividades como lazer, recreação, navegação e pesca haviam cessado ou diminuído consideravelmente.

Desconsiderando os *outliers*, percebe-se nas campanhas de maio, junho, agosto e outubro de 2021 uma distribuição simétrica dos dados, com valores de turbidez abaixo de 2 FNU. A maior variabilidade de turbidez pode ser observada, principalmente, nos meses de maio e setembro de 2021.

Feições derivadas e avaliação da performance

Os métodos empíricos são uma subdivisão das diferentes abordagens utilizadas para estimativa de parâmetros de qualidade de água e são construídos a partir de uma relação estatística entre feições derivadas dos espectros de reflectância e concentração mensurada de constituintes da água (Niroumand-Jadidi *et al.*, 2019). Diversos índices podem ser empregados de acordo com a resposta espectral do parâmetro estudado. A Figura 4.7 mostra o comportamento espectral da turbidez na área de estudo frente às diferentes feições selecionadas baseadas no sensor MSI.

Sabe-se que as bandas da região do vermelho e do NIR são frequentemente utilizadas para estimar a concentração de sólidos em águas altamente turvas (ver Tópico 2.2.4). A partir da Figura 4.7 é possível observar que a turbidez no Reservatório de Três Marias apresenta reflectância mais baixa na região do vermelho e do NIR (bandas 5 e 8, respectivamente) do que se comparada à outras regiões do espectro do visível (verde, banda 3 e azul, banda 2). Este fenômeno pode estar relacionado à baixa turbidez presente no reservatório. A Figura 4.7 também apresenta reflectância menos elevada

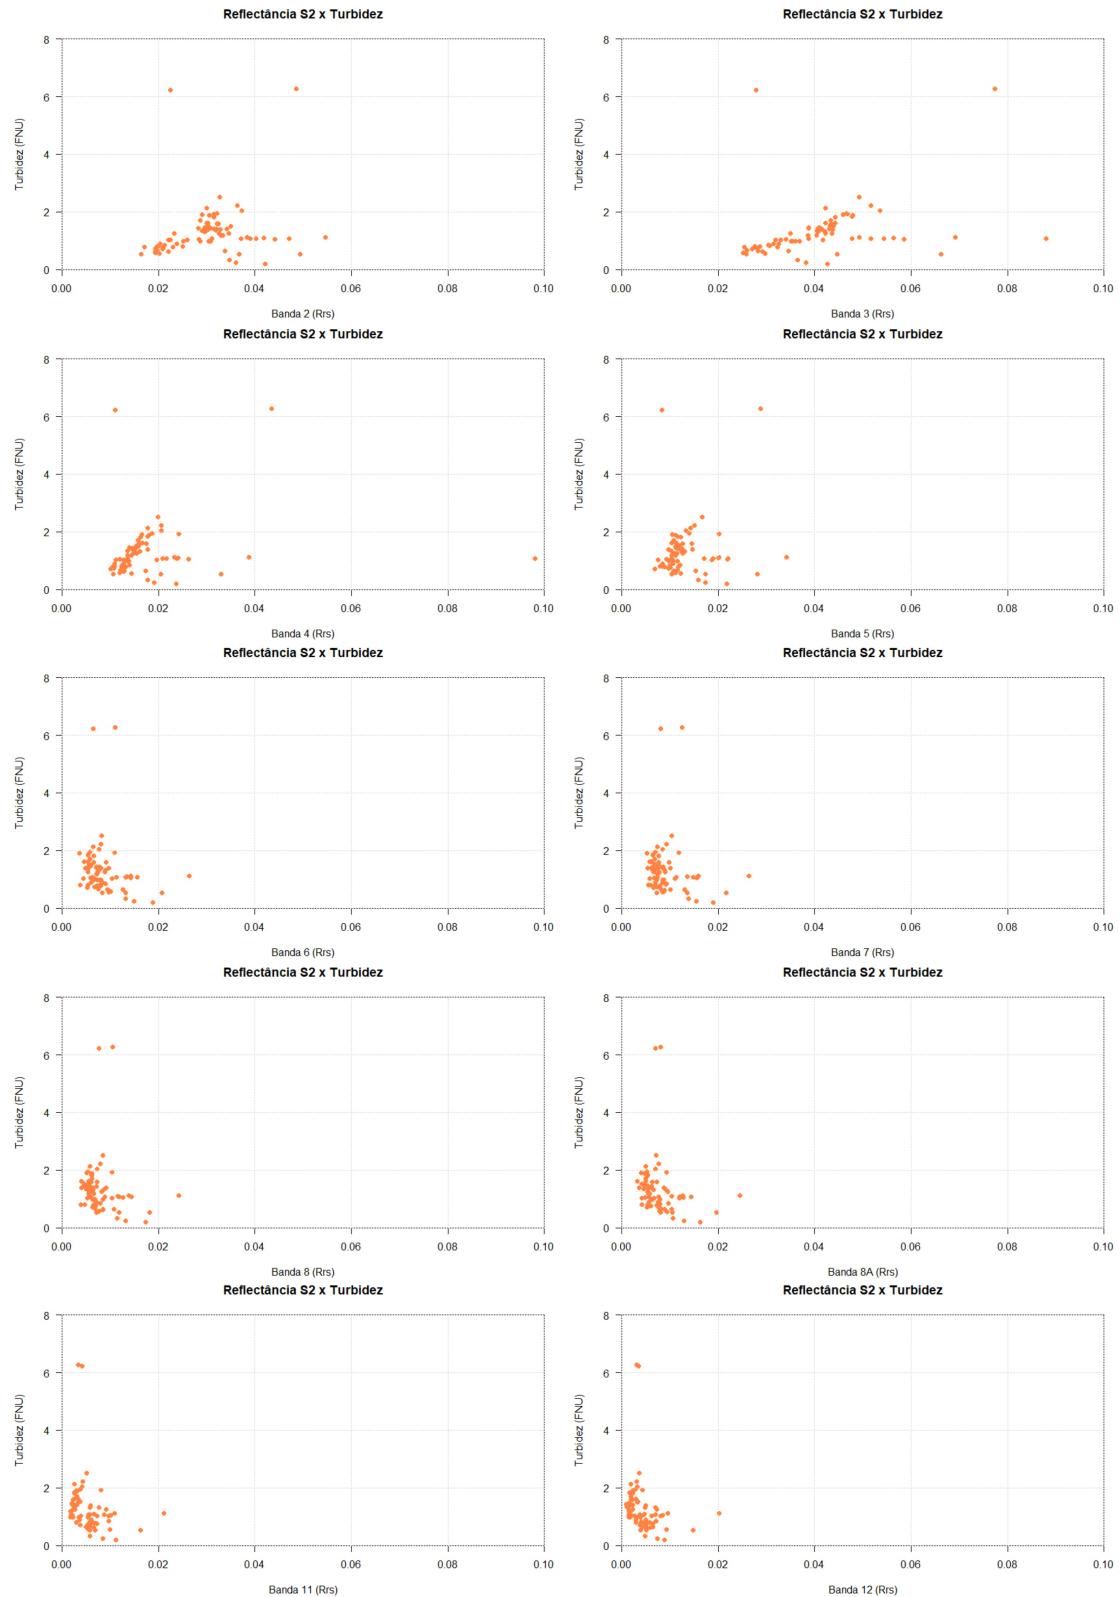


Figura 4.7: Relação entre turbidez e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.

nos comprimentos de onda na faixa do SWIR (bandas 11 e 12), o que sugere baixa concentração de sólidos em suspensão (diretamente relacionada à turbidez).

O comportamento espectral das demais feições selecionadas para o estudo ($Turb_1$, $Turb_3$, $Turb_4$, $Turb_5$ e $Turb_6$) podem ser observadas a partir da Figura 4.8. A figura retrata feições derivadas de estudos com foco na estimativa da qualidade da água presentes na literatura internacional cujos corpos d'água selecionados se aproximaram das características do Reservatório de Três Marias. O modelo $Turb_2$ não aparece na Figura por se tratar de uma RLM utilizando bandas espectrais combinadas dos sensores remotos (descritas na Figura 4.7).

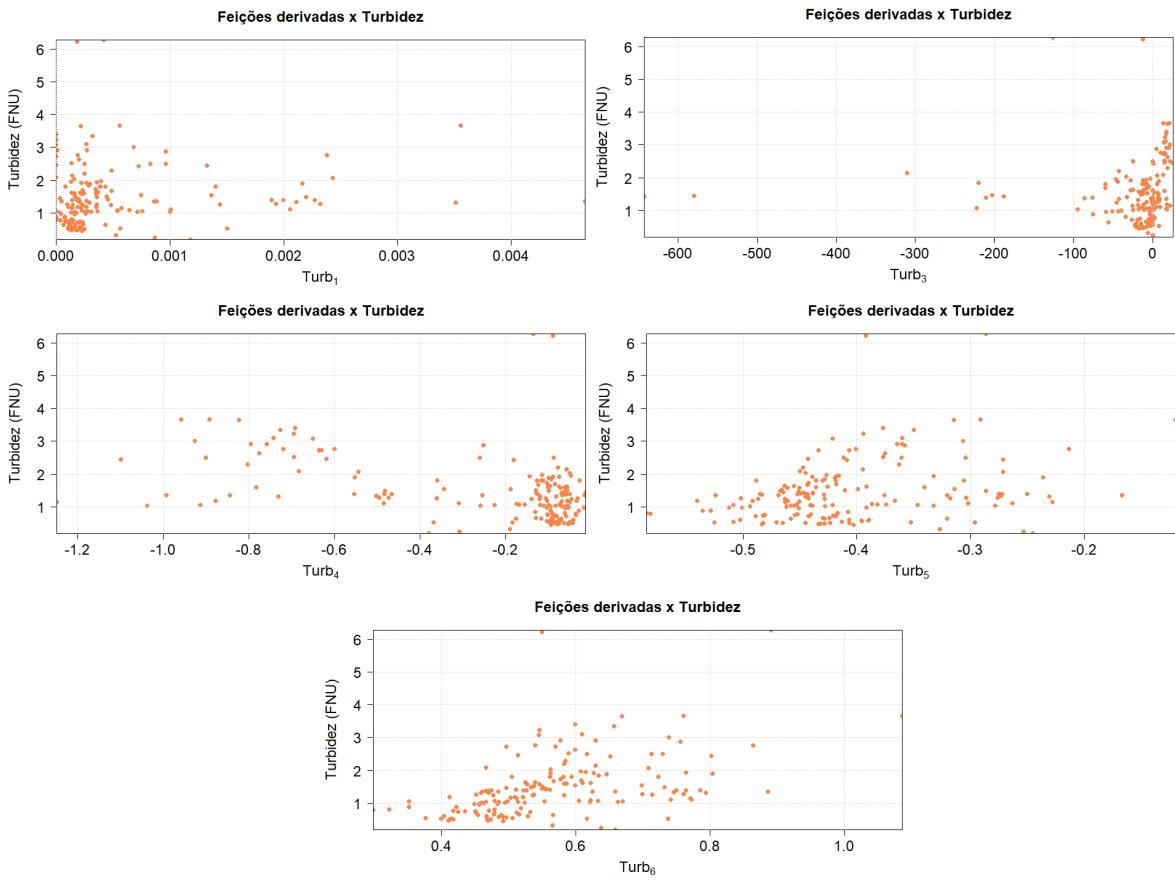


Figura 4.8: Relação entre turbidez e feições derivadas dos modelos da literatura no Reservatório de Três Marias.

Observa-se que as feições de $Turb_1$, $Turb_3$ e $Turb_4$ não apresentam comportamento linear, diferentemente das feições $Turb_5$ e $Turb_6$, mais alinhadas à reflectância do sensor. O cálculo do NDTI, representado pela feição $Turb_5$, registra valores que variam entre -1 e 1. De acordo com o índice, se a água tem baixa turbidez (como é o caso do reservatório de estudo), a reflectância tende a ser fraca na região espectral do verde (< 10%), fraquíssima na região do vermelho e praticamente nula no NIR (Lacaux *et al.*, 2007). De acordo com a escala, quanto mais próximo os valores de -1, mais clara é a água, enquanto valores mais próximos à 1 indicam águas mais turvas. Neste sentido, observamos que os valores obtidos no Reservatório de Três Marias, em nenhum momento, chegam a

atingir o valor 0, confirmando mais uma vez a baixa turbidez do ambiente aquático.

Após verificar o comportamento espectral das variáveis do estudo, foram testadas todas as bandas espectrais disponíveis no sensor MSI com resolução espacial de 10 m e 20 m e as variadas combinações e técnicas utilizadas entre elas com base na literatura científica, conforme as equações apresentadas na Tabela 3.5. Para efetuar os testes, utilizou-se o conjunto total de dados amostrados para turbidez (167 pontos amostrais). Os resultados das análises estatísticas para todo o conjunto de dados são apresentados na Tabela 4.2. Os valores de r^2 em vermelho são referentes aos melhores resultados considerando cada modelo individualmente. O objetivo dessa etapa foi o de comparar o desempenho de cada modelo separadamente.

Tabela 4.2: Performance da avaliação dos modelos individuais para turbidez.

ID	Feição	r^2	RMSE	MAE	p-value
$B2$	$\rho B2$	0,84	0,669	0,445	< 0,01
$B3$	$\rho B3$	0,88	0,578	0,387	< 0,01
$B4$	$\rho B4$	0,81	0,711	0,510	< 0,01
$B5$	$\rho B5$	0,75	0,824	0,603	< 0,01
$B6$	$\rho B6$	0,67	0,961	0,718	< 0,01
$B7$	$\rho B7$	0,67	0,949	0,707	< 0,01
$B8$	$\rho B8$	0,66	0,974	0,730	< 0,01
$B8A$	$\rho B8A$	0,64	1,000	0,759	< 0,01
$B11$	$\rho B11$	0,55	1,114	0,868	< 0,01
$B12$	$\rho B12$	0,51	1,167	0,907	< 0,01
$Turb_1$	$1048,8 * [(\rho B2 + \rho B8) * \rho B8]$	0,28	1,412	1,128	< 0,01
$Turb_2$	$0,419 + (-94,129 * \rho B2) + (56,261 * \rho B3) + (135,372 * \rho B4) + (-110,431 * \rho B8)$	0,65	0,535	0,264	< 0,01
$Turb_3$	$5,76 + 737,3 * (\rho B5 - \rho B11) - 2,277 * (\frac{\rho B2}{\rho B12})$	0,04	1,633	1,371	< 0,01
$Turb_4$	$0,4121 * [\frac{(\rho B8 * \rho B4)}{\rho B3}]^2 - 31,74 * [\frac{(\rho B8 * \rho B4)}{\rho B3}] + 612,17$	0,57	1,092	0,862	< 0,01
$Turb_5$	$NDTI = \frac{(\rho B4 - \rho B3)}{(\rho B4 + \rho B3)}$	0,66	0,976	0,714	< 0,01
$Turb_6$	$\frac{\rho B4}{\rho B2}$	0,80	0,735	0,536	< 0,01

Em relação às faixas espectrais, os resultados mostram que a medida em que o comprimento de onda aumenta, o desempenho do modelo diminui. Pela análise da Tabela 4.2 utilizando o conjunto total de dados é possível verificar que o melhor desempenho é provido pelas bandas espectrais da faixa do visível ($B3$, $B2$ e $B4$, respectivamente), com r^2 acima de 0,80. Fazendo uso da banda única $B3$, o coeficiente de determinação atingiu 0,88, RMSE = 0,578 FNU e MAE = 0,387 FNU. As bandas espectrais $B2$ e $B4$ apresentaram resultado similar ($r^2 = 0,84$, RMSE = 0,669 FNU, MAE = 0,445 FNU e $r^2 = 0,81$, RMSE = 0,711 FNU, MAE = 0,510 FNU, respectivamente). As três bandas do *red edge* geraram resultados de r^2 entre 0,67 e 0,75, enquanto as bandas NIR e SWIR apresentam r^2 entre 0,51 e 0,66. O resultado mostra que modelos simples podem produzir boas estimativas ao longo do tempo dentro dos limites do reservatório.

Os coeficientes de determinação menos significativos foram atribuídos aos modelos $Turb_1$ e

$Turb_3$ que resultaram em valores de r^2 inferiores a 0,28. Os resultados atribuídos ao modelo $Turb_5$ (NDTI), ainda que interessantes uma vez que pode ser usado como indicador do parâmetro, não foram tão positivos quanto ao modelo $Turb_6$ ou aos modelos envolvendo as bandas do visível. Como já levantado, supõe-se que os resultados possam ter alguma relação com a baixa concentração de turbidez encontrada no reservatório. O modelo $Turb_2$ alcançou resultado mediano similar ao cálculo do NDTI, utilizando as bandas do visível e do NIR. O modelo $Turb_6$ alcançou desempenho mais significativo, se comparado aos demais modelos da literatura ($r^2 = 0,80$). Dessa forma, conclui-se que, nas condições de baixa turbidez do Reservatório de Três Marias, as bandas simples apresentam melhor desempenho do que os índices de turbidez.

Seleção da feição

O processo para selecionar a(s) variável(is) dos três parâmetros estudados foi efetuado por meio da estimação do tipo *Knock-out*, um método de busca sequencial para variáveis significativas. Para tanto, primeiro foram avaliados os efeitos da multicolinearidade em cada modelo e examinadas as correlações diretas de todas as variáveis independentes potenciais. Esta etapa visa evitar conclusões precipitadas como, por exemplo, a suposição de que feições que não entraram no modelo não são importantes quando elas estão altamente relacionadas com a variável resposta e correlacionadas com variáveis do modelo (Hair *et al.*, 2005).

A multicolinearidade é inversamente proporcional à variância total explicada. Os resultados de cada modelo individual (Tabela 4.2) e o comportamento entre a turbidez e a reflectância espectral (Figuras 4.7 e 4.8) fornecem critérios para evitar os efeitos da multicolinearidade e para a análise na seleção do modelo final. A Tabela 4.3 apresenta a matriz com o coeficiente de correlação de Pearson e a Figura 4.9 representa graficamente os valores encontrados na Tabela 4.3 para as variáveis selecionadas.

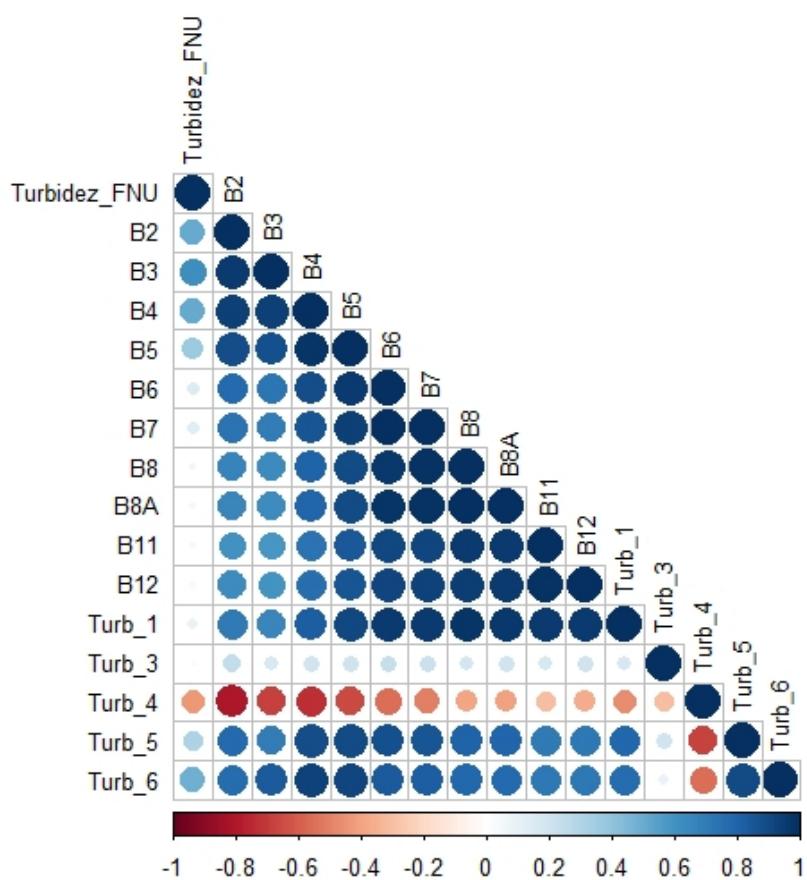


Figura 4.9: Gráfico da matriz de correlação para turbidez.

Tabela 4.3: Matriz de correlação para turbidez.

Turbidez _(FNU)	Turbidez _(FNU)	B2	B3	B4	B5	B6	B7	B8	B8A	B11	B12	Turb ₁	Turb ₃	Turb ₄	Turb ₅	Turb ₆
	1															
B2	0,91	1														
B3	0,94	0,95	1													
B4	0,90	0,94	0,93	1												
B5	0,87	0,89	0,87	0,98	1											
B6	0,82	0,78	0,72	0,88	0,95	1										
B7	0,82	0,74	0,70	0,86	0,94	0,99	1									
B8	0,81	0,66	0,63	0,80	0,90	0,97	0,98	1								
B8A	0,80	0,66	0,62	0,79	0,90	0,97	0,98	0,99	1							
B11	0,74	0,60	0,58	0,74	0,84	0,91	0,92	0,95	0,95	1						
B12	0,71	0,62	0,59	0,75	0,85	0,92	0,92	0,95	0,95	0,98	1					
Turb ₁	0,53	0,70	0,66	0,83	0,91	0,96	0,96	0,97	0,97	0,95	0,95	1				
Turb ₃	0,20	0,25	0,16	0,19	0,21	0,23	0,21	0,18	0,19	0,18	0,20	0,17	1			
Turb ₄	-0,75	-0,80	-0,68	-0,73	-0,66	-0,56	-0,50	-0,39	-0,40	-0,31	-0,37	-0,46	-0,30	1		
Turb ₅	0,81	0,77	0,70	0,88	0,89	0,87	0,85	0,80	0,80	0,70	0,71	0,78	0,20	-0,67	1	
Turb ₆	0,89	0,77	0,83	0,93	0,91	0,83	0,83	0,79	0,77	0,71	0,71	0,76	0,09	-0,56	0,89	1

Com base nos dados da Tabela 4.3 e da Figura 4.9 observa-se que a correlação entre as bandas espectrais e o índice de turbidez decrescem a medida que o comprimento de onda aumenta e comprova a maior correlação positiva entre turbidez e a B3 (0,94). As bandas 8 (0,81), 8A (0,80), 11 (0,74), 12 (0,71) e as variáveis $Turb_1$ (0,53) e $Turb_3$ (0,20) apresentaram os menores índices de correlação com o parâmetro estudado.

A seleção efetuada via *Knock-Out* visa ranquear as variáveis levando em consideração os efeitos da multicolinearidade. A Tabela 4.4 apresenta os resultados da aplicação do algoritmo de acordo com o estágio. Como esperado, as bandas do visível, em especial B3, apresentaram as melhores contribuições à estimativa do parâmetro, bem como as bandas do *red edge* B5 e B6. Analisando os resultados encontrados em conjunto, pressupõe-se que as bandas espectrais da faixa do visível sejam as mais importantes para a estimativa da turbidez. Dessa forma, além das bandas do visível, as variáveis $Turb_5$ e $Turb_6$ (que utilizam as bandas do visível para a composição de seus modelos) também serão consideradas para a seleção do modelo final. Observando o ótimo desempenho da banda azul (B2) e verde (B3) do Sentinel-2, foi testado o uso de uma razão baseada nessas duas bandas a fim de aferir seu desempenho frente aos outros índices.

Tabela 4.4: Resultado da seleção de variáveis por *ranking* via *Knock-out* para turbidez.

Estágio	Geral	r^2	04/10/2019	r^2	31/05/2020	r^2	06/05/2021	r^2	20/06/2021	r^2	24/08/2021	r^2	23/09/2021	r^2	28/10/2021	r^2
1	B11	0,96	B7	0,98	B5	0,99	B12	0,98	B8	0,99	B4	0,97	B7	0,98	B8A	0,98
2	B6	0,96	B12	0,98	B7	0,99	B4	0,98	B12	0,99	B11	0,97	B12	0,98	B12	0,98
3	B12	0,96	B2	0,98	B8	0,99	B6	0,98	B6	0,99	B8A	0,98	B11	0,98	B7	0,98
4	B7	0,96	B5	0,97	B11	0,99	B8	0,98	B2	0,99	B12	0,98	B5	0,98	B4	0,98
5	B8	0,95	B11	0,95	B2	0,99	B7	0,98	B11	0,99	B8	0,98	B8A	0,98	B8	0,98
6	B5	0,95	B8	0,95	B12	0,99	B11	0,98	B4	0,99	B7	0,97	B6	0,98	B2	0,98
7	B3	0,95	B4	0,95	B8A	0,99	B8A	0,98	B7	0,98	B6	0,97	B4	0,98	B11	0,98
8	B2	0,94	B8A	0,95	B6	0,99	B5	0,98	B5	0,99	B5	0,97	B2	0,98	B3	0,97
9	B8A	0,93	B6	0,91	B3	0,98	B2	0,98	B8A	0,99	B2	0,97	B8	0,97	B6	0,94
10	B4	0,82	B3	0,86	B4	0,94	B3	0,96	B3	0,97	B3	0,92	B3	0,92	B5	0,81

No Estágio 1, todas as combinações possíveis de variáveis N-1 são realizadas eliminando a variável não incluída no melhor resultado. Repete-se o processo até que todas as variáveis tenham sido ranqueadas. O *ranking* final é apresentado em ordem decrescente.

Variação dos coeficientes

Os coeficientes de regressão (β) estimados são usados para calcular os valores previstos para cada observação e para expressar a variação esperada na variável dependente para cada variação unitária na(s) variável(is) independente(s) (Hair *et al.*, 2005). A Figura 4.10 mostra a variação dos β para cada variável selecionada calculada isoladamente utilizando todas as campanhas onde houve mensuração da turbidez. Ainda foram acrescentadas a variável $\frac{B3}{B2}$ e a razão de diferença normalizada $\frac{(B3-B2)}{(B3+B2)}$ considerando a contribuição destas bandas para a estimativa do parâmetro e a resposta espectral elevada atribuída a elas. À razão de diferença normalizada $\frac{(B3-B2)}{(B3+B2)}$ será atribuída a sigla NLTDI (*Normalised Low Turbidity Difference Index* – Índice de Diferença Normalizada de Baixa Turbidez).

A partir dos dados amostrados em campo foi possível observar pequenas variações nos dados de turbidez, que se mantiveram (em 94% das amostras) entre 0,2 e 3,0 FNU. Considerando que o número representado por β retrata a mudança consistente em cada modelo, destacam-se na Figura 4.10, principalmente, os menores e mais estáveis valores que são provenientes dos cálculos das variáveis: $Turb_5$, $Turb_6$, $\frac{B3}{B2}$ e NLTDI.

Também foi avaliada a variação dos β quando combinadas às três bandas do visível. O *boxplot* representado pela Figura 4.11 apresenta a distribuição gráfica dos β nas quatro possíveis associações das bandas 2, 3 e 4. Nota-se que, para o conjunto total de dados, a combinação B2+B3 (c) indica valores de β mais normalizados, onde B2 apresenta de forma consistente valores negativos e B3, positivos. Neste contexto, o que se observa é que quanto maior o índice de turbidez, menor a reflectância em B2 e maior a reflectância em B3.

Modelo selecionado

Com base na análise dos dados para o modelo de turbidez, as variáveis $\beta_1\rho B2 + \beta_2\rho B3$, $Turb_5$, $Turb_6$, $\frac{B3}{B2}$ e NLTDI baseadas no sensor MSI/Sentinel-2 foram selecionadas de acordo com o seu comportamento em relação à turbidez amostrada a fim de se verificar o desempenho entre os dados observados e os dados preditos. Os resultados das análises são apresentados na Tabela 4.5. Cada linha representa um conjunto de dados e a última linha mostra o coeficiente de variação (razão entre o desvio padrão e a média) dos pesos β da regressão.

Observa-se que, com as variáveis selecionadas, a campanha de 31/05/2020 apresentou o menor desempenho se comparada às demais campanhas, com r^2 alcançando 0,49 e RMSE = 1,619 FNU para a feição $Turb_5$. Na sequência, o segundo menor desempenho dos modelos foi atribuído ao conjunto de dados completo (geral) referente à todas as campanhas de campo, onde os valores de r^2 variaram entre 0,66 e 0,90 e RMSE entre 0,518 FNU e 0,976 FNU. Para as demais campanhas, os valores de r^2 superaram 0,80, com especial atenção à campanha de 06/05/2021 que apresentou, para todos os modelos, valores superiores à r^2 0,91 e RMSE abaixo de 0,427 FNU.

Com relação ao desempenho individual dos modelos, destaca-se o modelo representado pela RLM definida por $\beta_1\rho B2 + \beta_2\rho B3$. Assim como os demais modelos, a campanha de 31/05/2020 apresentou o desempenho mais baixo entre as demais com $r^2 = 0,89$ e RMSE = 0,694 FNU. Em

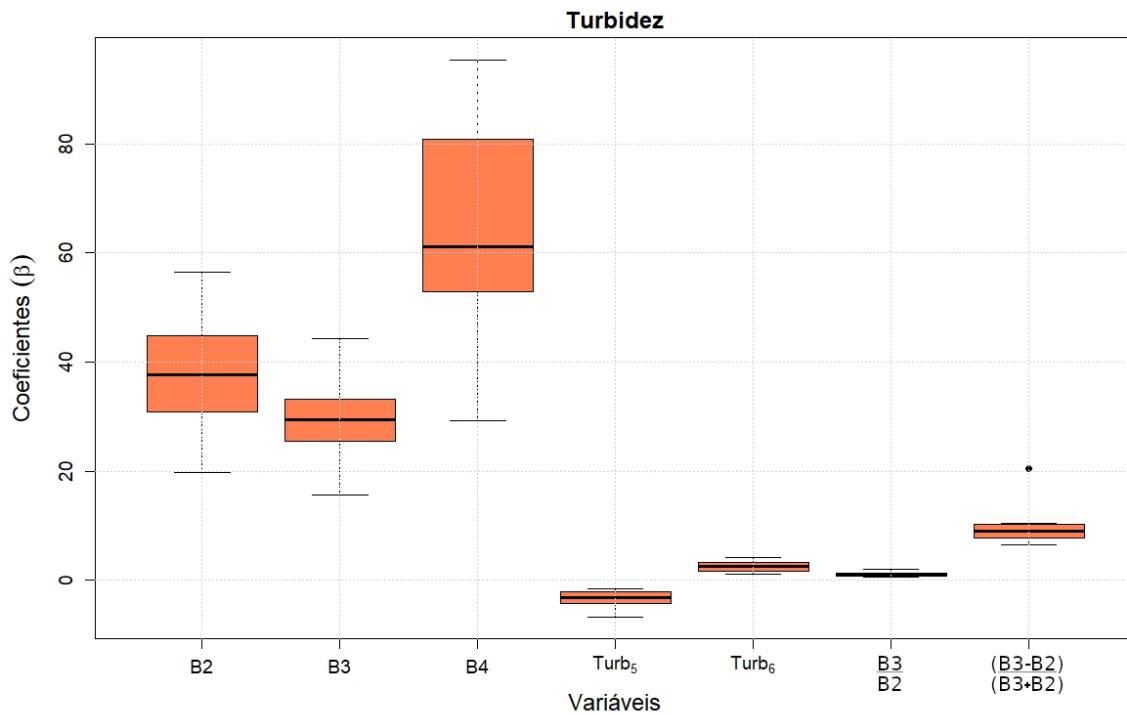


Figura 4.10: Variação dos coeficientes para turbidez.

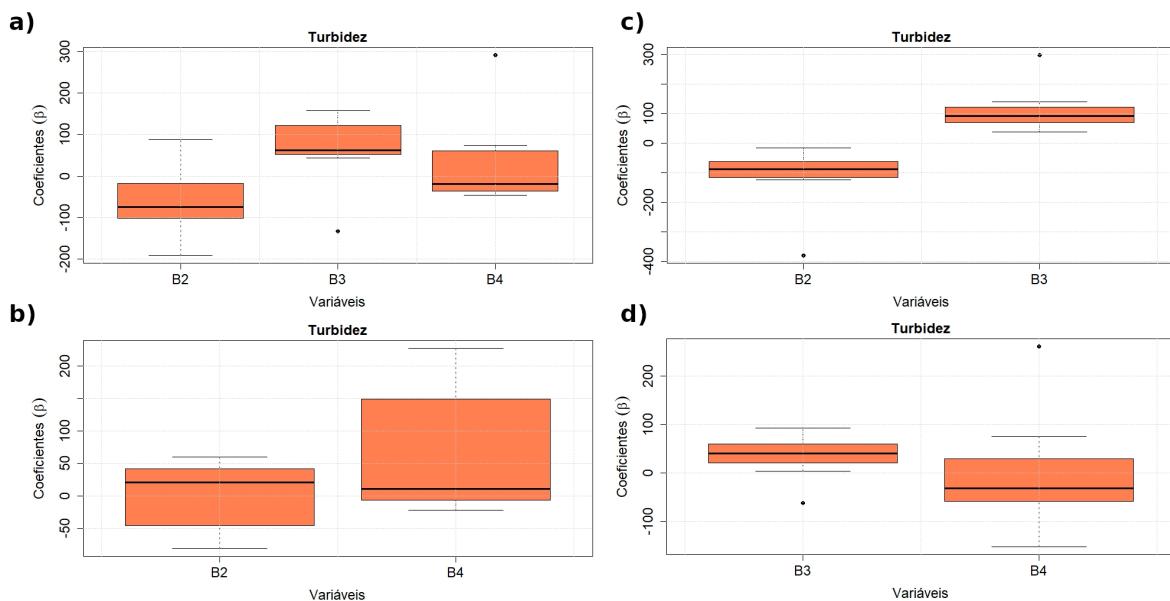


Figura 4.11: Variação dos coeficientes para turbidez utilizando combinações das bandas do visível: a) $\beta_1\rho B2 + \beta_2\rho B3 + \beta_3\rho B4$; b) $\beta_1\rho B2 + \beta_2\rho B3$; c) $\beta_1\rho B2 + \beta_3\rho B4$ e; d) $\beta_2\rho B3 + \beta_3\rho B4$.

Tabela 4.5: Resultados estatísticos da classificação de feições da melhor combinação de bandas espectrais e dos diferentes índices de turbidez indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação dos β .

Campanha	$\beta_1\rho B2 + \beta_2\rho B3$				$Turb_5$			$Turb_6$			$\frac{B3}{B2}$			NLTDI		
	r^2	RMSE	β B2	β B3	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
Geral	0,90	0,518	-59,002	76,043	0,66	0,976	-3,3133	0,80	0,735	2,61571	0,77	0,791	1,11891	0,80	0,740	10,5442
04/10/2019	0,90	0,238	-49,50	53,64	0,85	0,307	-2,4394	0,82	0,337	1,1886	0,87	0,292	0,6225	0,94	0,198	6,4083
31/05/2020	0,89	0,694	-379,63	-294,54	0,49	1,619	-3,913	0,79	1,037	3,580	0,66	1,323	1,3258	0,70	1,227	10,359
06/05/2021	0,98	0,198	-83,46	96,60	0,91	0,427	-3,1390	0,97	0,239	2,78746	0,96	0,282	1,0576	0,97	0,236	9,0926
20/06/2021	0,97	0,129	-13,72	38,57	0,90	0,274	-1,887	0,91	0,252	1,9321	0,92	0,238	0,7274	0,85	0,344	8,5021
24/08/2021	0,97	0,128	-86,513	92,898	0,83	0,314	-1,6159	0,87	0,278	1,5379	0,87	0,269	0,5964	0,94	0,176	7,0032
23/09/2021	0,96	0,474	-112,14	131,37	0,88	0,881	-6,7117	0,90	0,792	4,0822	0,93	0,670	1,9774	0,96	0,510	20,5391
28/10/2021	0,95	0,391	-120,90	117,32	0,80	0,783	-4,4888	0,92	0,474	2,5213	0,91	0,510	1,2341	0,91	0,528	10,2710
Coef. Var.	-1,000				-0,478			0,387			0,422			0,426		

Legenda:  $r^2 > 0,90$  $r^2 0,80\text{--}0,89$  $r^2 0,70\text{--}0,79$  $r^2 0,60\text{--}0,69$  $r^2 0,50\text{--}0,59$  $r^2 < 0,50$

sequência, tem-se o conjunto total de dados (geral), com $r^2 = 0,90$ e RMSE = 0,518 FNU. Para as demais campanhas que fizeram uso desse modelo, o valor de r^2 superou 0,90 e RMSE < 0,238 FNU. Embora a regressão de duas bandas $\beta_1\rho B2 + \beta_2\rho B3$ aparente ter um desempenho melhor no geral, os coeficientes de variação são muito maiores do que no caso dos índices, o que implica um comportamento mais errático e modelos menos robustos.

Em todos os casos, o modelo $Turb_5$ mostrou-se inferior se comparado aos outros modelos. Ainda que apresentando bons resultados, neste momento, a suposição de que, em função da baixa turbidez e baixa presença de material particulado em suspensão no reservatório, o NDTI não seja a melhor escolha de modelo para águas de baixa turbidez, se fortalece.

No modelo $Turb_5$, verifica-se consistentemente valores de β negativos indicando que, neste contexto, a medida que a turbidez aumenta, o NDTI diminui. Quando observada a relação entre as bandas B3 e B2, verifica-se valores de β positivos, que implica em uma relação positiva entre as variáveis predita e preditora. É interessante ressaltar que o coeficiente de variação do índice NLTDI é de 0,426 em oposição a -0,478 para o NDTI.

Validação do modelo

O modelo referente ao índice NLTDI foi aplicado ao conjunto geral de dados. A Figura 4.12 apresenta os valores dos dados amostrados *in situ* vs. os dados preditos pelo modelo selecionado. A Figura 4.12 possibilita a identificação de onde ou em qual momento os erros do modelo foram mais significativos. Os pontos são ilustrados em ordem crescente de acordo com a cronologia dos campos (sendo o primeiro em 04/10/2019 e o último em 28/10/2021).

Os pontos referentes aos números que variam de 108 a 133 correspondem à sexta campanha, de 23/09/2021. A campanha em questão apresentou a maior média de valores de turbidez entre todas as campanhas (2,5 FNU), com valores variando de 1,04 FNU a 3,67 FNU, enquanto os valores preditos pelo modelo apresentou média de 1,27 FNU, com variação entre 0,4 FNU e 1,76 FNU. A trajetória amostral dos pontos se deu a partir do Rio Indaiá, próximo às áreas de piscicultura do município de Morada Nova de Minas, e se estendeu até, aproximadamente, 7 km no Rio Paraopeba, a partir do Rio

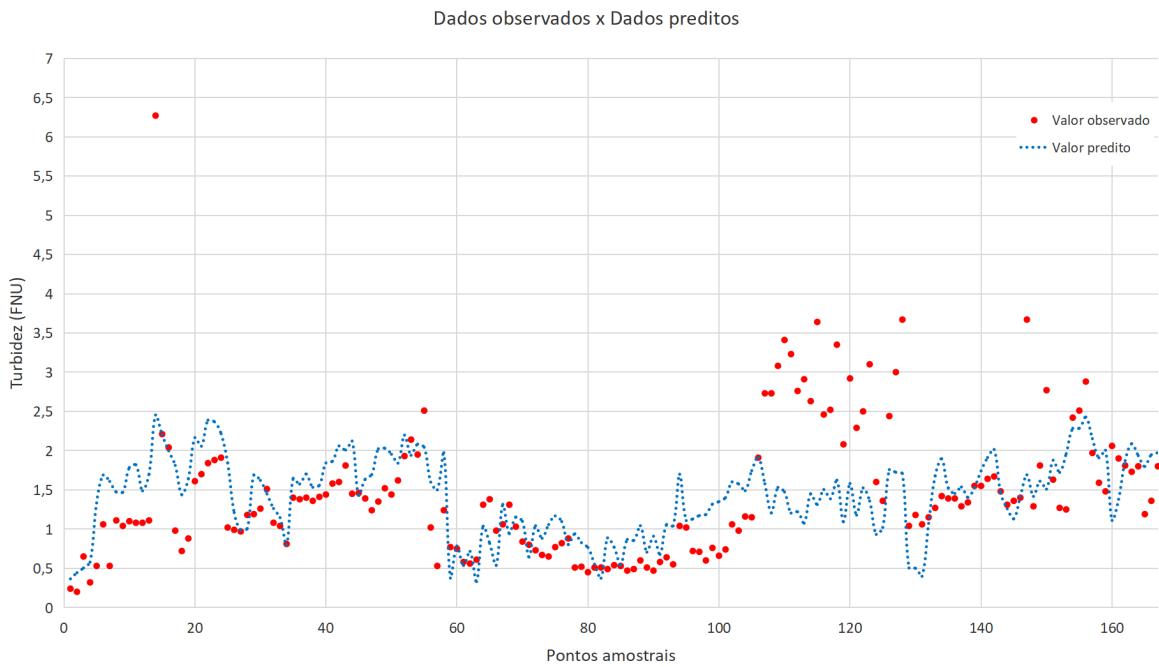


Figura 4.12: Dados observados *vs.* dados preditos utilizando o índice NLTDI para o conjunto geral de dados.

São Francisco.

Neste contexto geral, o modelo de regressão referente ao índice NLTDI alcançou um $r^2 = 0,80$, RMSE = 0,740 FNU e $p\text{-value} < 0,01$. O gráfico ilustrando a equação e o resultado do desempenho entre o modelo e a turbidez é apresentado na Figura 4.13. Observa-se que, quanto maior a turbidez, maior a dispersão e menor ajuste dos dados.

Com base nos resultados alcançados para o Reservatório de Três Marias, um reservatório com condição ultraoligotrófica a oligotrófica, observa-se que, por melhor que os modelos se apresentem em algumas campanhas específicas, não há modelo de regressão ou índices de turbidez robustos o suficiente para serem utilizados diretamente sem calibração. A fim de operacionalizar a obtenção da estimativa do parâmetro, a calibração do modelo foi executada com base em dois pontos específicos do reservatório mensurados *in situ*: um ponto a jusante (próximo à barragem, onde os valores de turbidez costumam ser menos elevados, se comparados aos demais) e um ponto a montante (próximo à confluência entre os rios São Francisco e Paraopeba, que abastecem o reservatório). Para tanto, utilizou-se o *software* livre [SIMOA SAT](#). Por meio da ferramenta foi possível construir de forma automatizada o índice de turbidez NLTDI por campanha e selecionar manualmente os pontos amostrados de acordo com a data. O uso de tal procedimento pode tornar esses modelos e índices muito mais confiáveis e reduzir significativamente seus erros.

A Figura 4.14 mostra os erros (diferença entre os valores medidos e observados) por pontos de amostragem em cada levantamento. A Tabela 4.6 mostra os erros obtidos calibrando o índice NLTDI utilizando dois pontos situados nas mesmas áreas (a jusante e a montante). Estes valores são muito semelhantes aos obtidos através da regressão linear individual para cada campanha *in situ* com todas

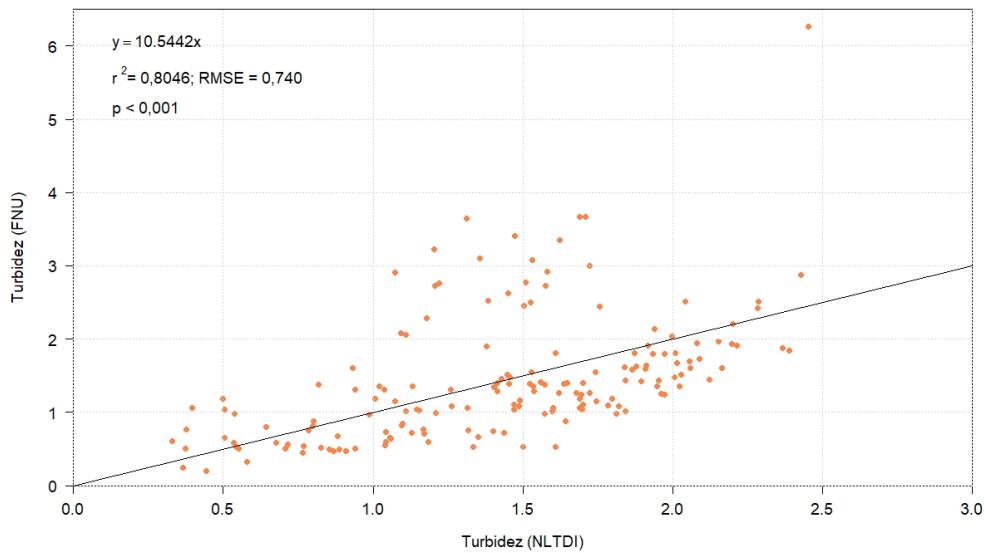


Figura 4.13: Modelo de regressão utilizando o índice NLTDI para o conjunto geral de dados sem calibração.

as medições efetuadas (entre 12 e 35 pontos).

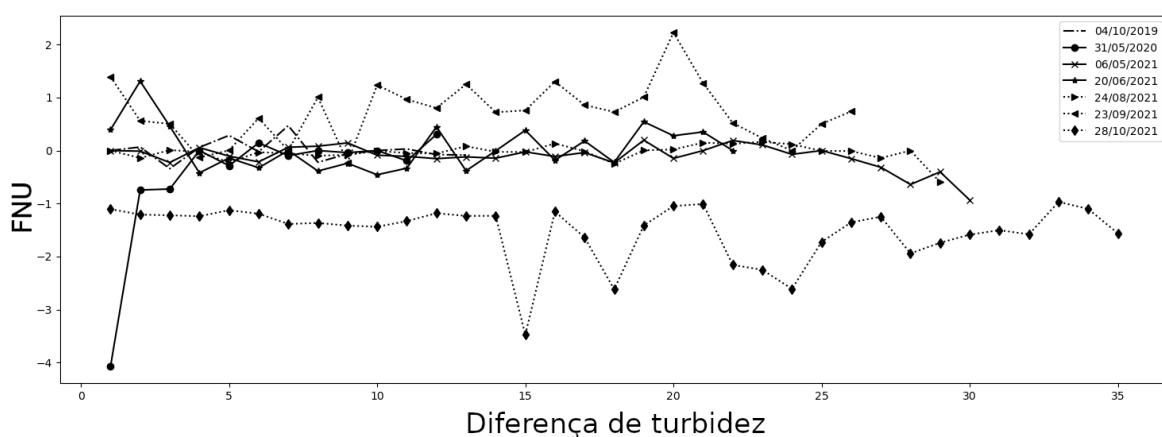


Figura 4.14: Gráfico mostrando a diferença entre as concentrações medidas de turbidez e os valores obtidos pela calibração dos índices de dados Sentinel-2/MSI.

4.2.2 Profundidade do Disco de Secchi

Conforme presente no Tópico 2.2.4, a transparência obtida por meio da Profundidade do Disco de Secchi (SDD) contém propriedades ópticas semelhantes àquelas encontradas no parâmetro de turbidez, fato que permite, em alguns casos, a mesma combinação de bandas espectrais utilizadas para a estimativa dos dois parâmetros (Avdan *et al.*, 2019). Assim como acontece com sedimentos

Tabela 4.6: RMSE e MAE obtidos para valores de turbidez após calibração do índice NLTDI usando dois pontos de medição *in situ*. A campanha de 28/10/2021 foi excluída pois não foram feitas mensurações próximas aos pontos adotados (montante/jusante).

Turbidez	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021	Média
RMSE (FNU)	0,1948	1,1749	0,2563	0,4265	0,1491	0,9068	0,5181
MAE (FNU)	0,1324	0,5270	0,1696	0,3379	0,0914	0,7518	0,3350

em suspensão, SDD e turbidez são altamente correlacionados. Para o Reservatório de Três Marias, os resultados encontrados e a discussão dos parâmetros tiveram bastante similaridade.

O *boxplot* na Figura 4.15 mostra o intervalo referente à SDD obtido durante os levantamentos de campo realizados em oito campanhas. Foram utilizados 175 pontos onde a transparência do Reservatório de Três Marias variou entre 160 cm e 599 cm. A transparência mais baixa da água foi encontrada, principalmente, na campanha de setembro de 2021, na qual 46% dos valores de Secchi oscilaram entre 160 cm e 200 cm. Os maiores índices de transparência foram identificados na campanha de outubro de 2019. Nas proximidades do barramento foram registrados valores de transparência entre 448 cm e 599 cm.

Como ocorreu nos registros de turbidez, o reservatório apresentou comportamento inverso às demais campanhas naquela realizada em maio de 2020 com relação à SDD. Os menores valores de transparência se encontraram próximo à barragem com variação entre 175 cm e 195 cm. A maior transparência para esta campanha (515 cm) foi encontrada na porção central do reservatório, próximo à localidade de São José do Buriti (Felixlândia). Na confluência entre os rios São Francisco e Paropeba, esperava-se encontrar menor transparência do corpo d'água. No entanto, foram identificados valores medianos nesta região (entre 260 cm e 285 cm).

Percebe-se, no geral por meio das campanhas, alta clareza da água alcançando média de 300 cm e baixo coeficiente de variação (26,30%).

Feições derivadas e avaliação da performance

A Figura 4.16 mostra o comportamento espectral da SDD na área de estudo frente às diferentes feições selecionadas baseadas no sensor MSI.

A partir da Figura 4.16 é possível observar que a transparência no Reservatório de Três Marias apresenta maior reflectância na região do visível, especialmente nas bandas 3 e 2, respectivamente. Observa-se que, a medida que o comprimento de onda aumenta, a reflectância da água diminui, tornando-se mais baixa na região do SWIR (bandas 11 e 12). A baixa turbidez do reservatório, bem como a baixa concentração de sólidos suspensos, implicam em transparência mais elevada e, consequentemente, menor reflectância espectral do corpo hídrico.

As demais feições selecionadas para o estudo, classificadas em SDD_1 , SDD_2 , SDD_3 , SDD_4 e SDD_5 , apresentam comportamento ilustrado na Figura 4.17. As feições citadas são referentes aos modelos da literatura internacional cujos corpos d'água se assemelham em termos de transparência ao Reservatório de Três Marias ou utilizam do sensor MSI para estimativa do parâmetro.

A partir da Figura 4.17, é possível observar clara relação linear positiva para as feições SDD_1 ,

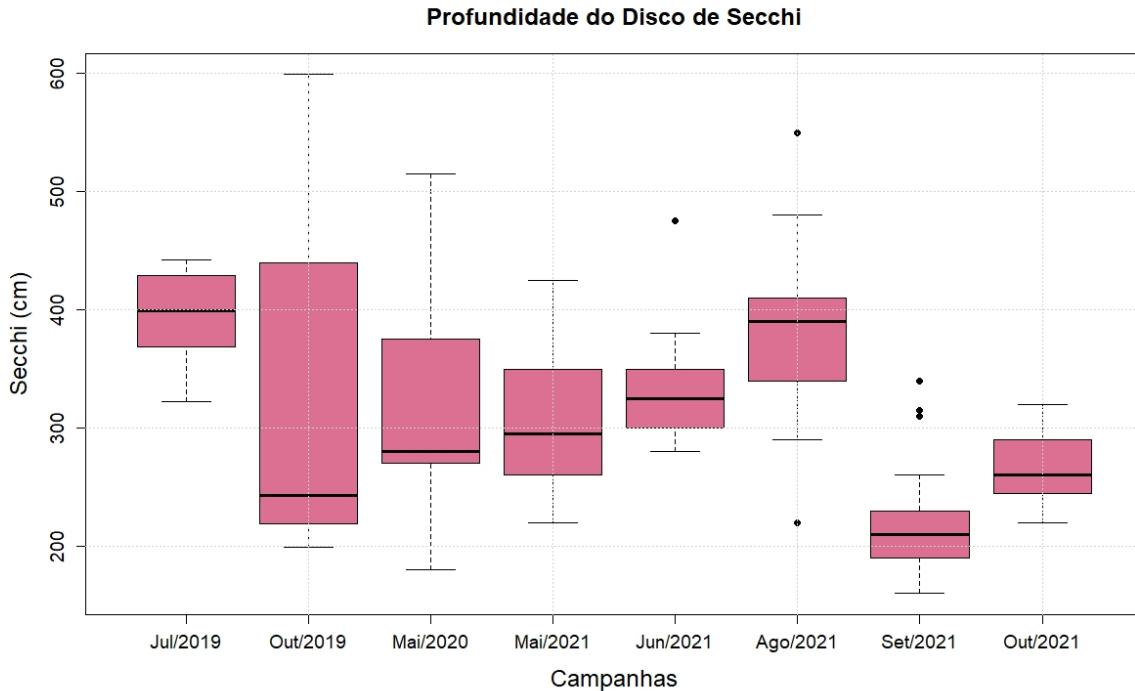


Figura 4.15: *Boxplot* da SDD para as campanhas de campo.

SDD_2 e SDD_5 , onde quanto maior o valor de observação, maior o valor estimado. Estas feições utilizam alguma razão de banda em seus modelos sendo todas elas em composição com a banda 2. A feição SDD_3 , que utiliza as bandas 4 e 3 em seu modelo, também apresenta relação linear, porém em menor evidência se comparada às três feições citadas. O modelo SDD_4 não apresentou boa relação linear e variou entre valores negativos e positivos para o parâmetro.

As feições selecionadas foram testadas com o conjunto total de dados amostrados para SDD (175 pontos) e as bandas espectrais do sensor MSI resultando na estatística apresentada na Tabela 4.7. Os modelos cujos resultados individuais foram superiores estão destacados em vermelho.

A Tabela 4.7 apresenta resultados coerentes com o comportamento espectral de cada feição e comprova que as feições com melhor desempenho para estimativa da SDD, considerando o conjunto geral de dados, são aquelas descritas na literatura. As feições SDD_1 , SDD_2 e SDD_5 atingiram r^2 acima de 0,90 e erro de ordem centimétrica ($RMSE < 88$ cm e $MAE < 66$ cm). Apesar do erro mais significativo, a feição SDD_3 também obteve bom desempenho, com $r^2 = 0,82$ e $RMSE = 131,62$ cm. Ao contrário dos demais modelos, a feição SDD_4 obteve fraquíssimo desempenho ($r^2 < 0,01$, $RMSE = 312$ cm e $p\text{-value} = 0,12$).

Quanto às bandas espectrais do sensor MSI, assim como ocorre com os dados de turbidez, o desempenho do modelo diminui quanto maior for o comprimento de onda. Fazendo uso de banda única, o melhor resultado pode ser atribuído à banda 3 cujo coeficiente de determinação atingiu 0,68, $RMSE = 175,9$ cm e $MAE = 145,91$ cm, seguido das bandas 2 e 4. No entanto, o melhor modelo de banda única ainda apresenta resultado inferior àqueles registrados pela literatura.

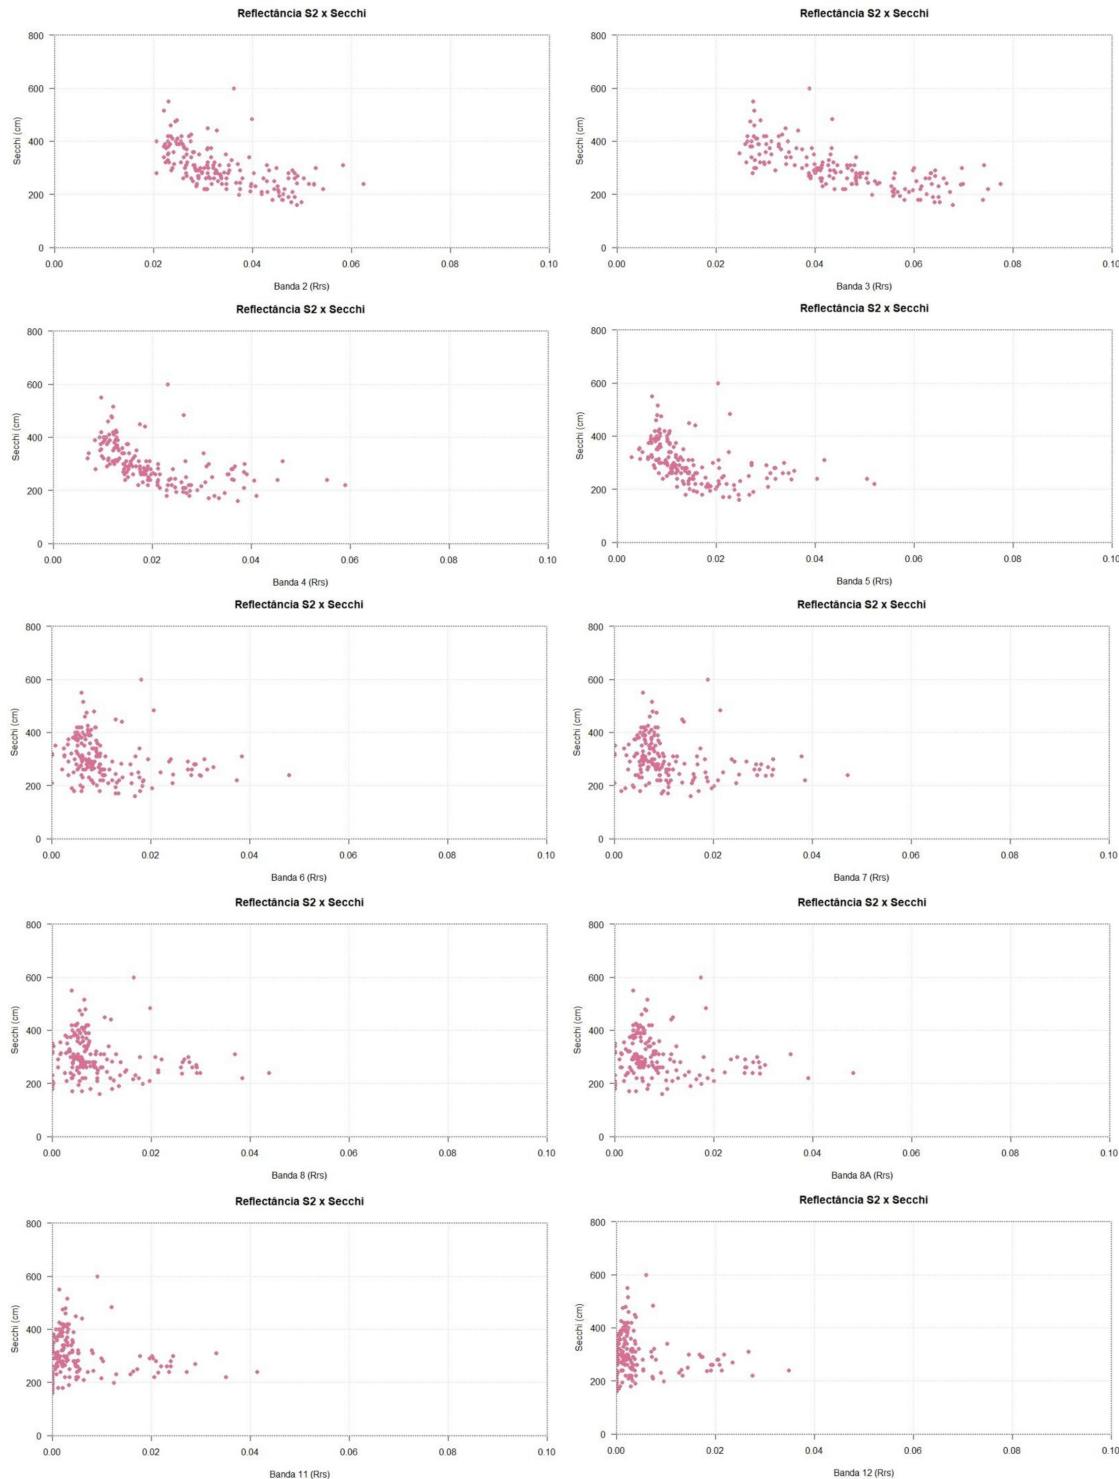


Figura 4.16: Relação entre SDD e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.

Seleção da feição

Antes da aplicação do método de seleção de variáveis *Knock-Out*, foi verificada a correlação entre as feições para SDD. A Tabela 4.8 apresenta a matriz com o coeficiente de correlação de Pe-

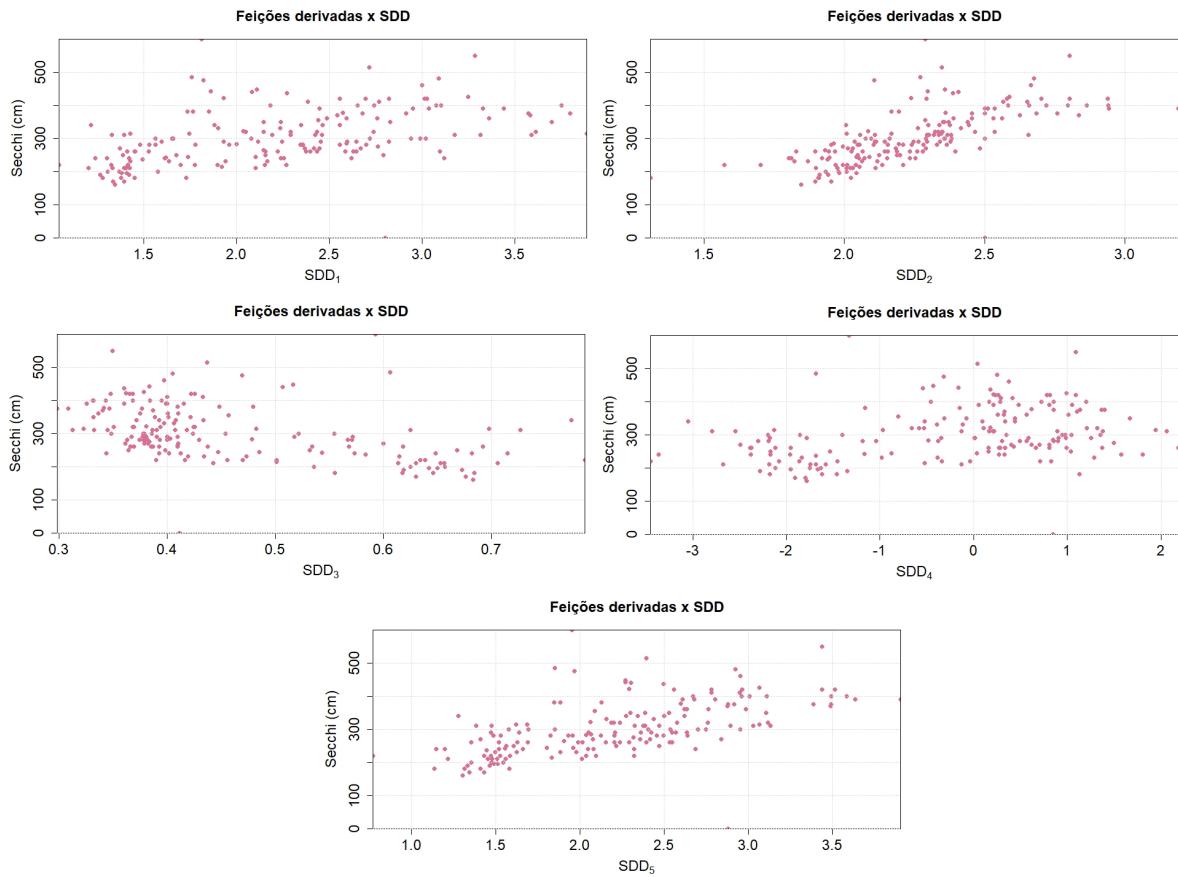


Figura 4.17: Relação entre SDD e feições derivadas dos modelos da literatura no Reservatório de Três Marias.

arson e a Figura 4.18 representa graficamente os valores encontrados na Tabela 4.8 para as variáveis selecionadas.

Tabela 4.7: Performance da avaliação das feições individuais para SDD.

ID	Feição	r^2	RMSE	MAE	p-value
$B2$	$\rho B2$	0,65	183,51	156,75	< 0,01
$B3$	$\rho B3$	0,68	175,90	145,91	< 0,01
$B4$	$\rho B4$	0,51	218,42	192,50	< 0,01
$B5$	$\rho B5$	0,44	233,17	208,70	< 0,01
$B6$	$\rho B6$	0,40	242,52	219,49	< 0,01
$B7$	$\rho B7$	0,41	240,29	217,13	< 0,01
$B8$	$\rho B8$	0,39	243,40	220,40	< 0,01
$B8A$	$\rho B8A$	0,39	244,26	220,62	< 0,01
$B11$	$\rho B11$	0,35	251,52	220,65	< 0,01
$B12$	$\rho B12$	0,34	253,69	222,76	< 0,01
SDD_1	$\frac{\rho B2}{\rho B5}$	0,92	88,00	65,70	< 0,01
SDD_2	$\frac{(\rho B2 + \rho B8)}{\rho B4}$	0,95	70,84	46,88	< 0,01
SDD_3	$\frac{\rho B4}{\rho B3}$	0,82	131,62	111,66	< 0,01
SDD_4	$-8,753 * (\frac{\rho B8}{\rho B2}) + 5,223 * \rho B8 + 2,552$	< 0,01	312,02	295,36	0,12
SDD_5	$1,806 * (\frac{\rho B2}{\rho B4}) - 0,8903$	0,94	76,11	53,62	< 0,01

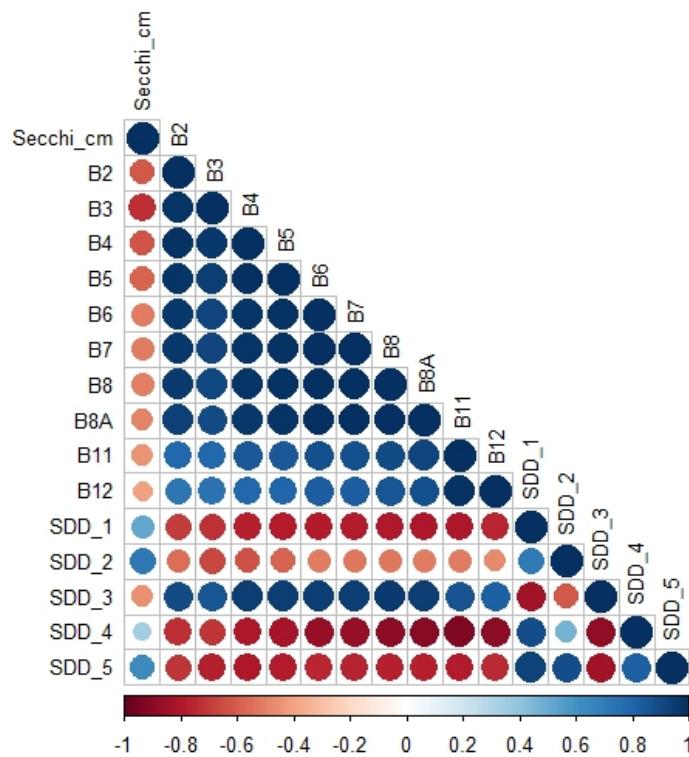


Figura 4.18: Gráfico da matriz de correlação para SDD.

Tabela 4.8: Matriz de correlação para SDD.

$\text{Secchi}_{(cm)}$	$\text{Secchi}_{(cm)}$	B2	B3	B4	B5	B6	B7	B8	B8A	B11	B12	SDD ₁	SDD ₂	SDD ₃	SDD ₄	SDD ₅
Secchi _(cm)	1,00															
B2	-0,62	1,00														
B3	-0,73	0,97	1,00													
B4	-0,63	0,98	0,97	1,00												
B5	-0,58	0,98	0,95	0,99	1,00											
B6	-0,51	0,96	0,91	0,97	0,99	1,00										
B7	-0,52	0,96	0,91	0,98	0,99	1,00	1,00									
B8	-0,51	0,95	0,91	0,97	0,99	1,00	1,00	1,00								
B8A	-0,50	0,94	0,90	0,96	0,98	0,99	0,99	0,99	1,00							
B11	-0,44	0,78	0,78	0,84	0,85	0,87	0,88	0,90	0,91	1,00						
B12	-0,41	0,72	0,73	0,79	0,80	0,83	0,83	0,85	0,87	0,99	1,00					
SDD ₁	0,51	-0,69	-0,72	-0,77	-0,79	-0,78	-0,79	-0,80	-0,80	-0,80	-0,76	1,00				
SDD ₂	0,71	-0,55	-0,67	-0,64	-0,59	-0,52	-0,52	-0,52	-0,52	-0,52	-0,48	0,70	1,00			
SDD ₃	-0,46	0,90	0,85	0,94	0,95	0,95	0,95	0,95	0,95	0,87	0,82	-0,83	-0,61	1,00		
SDD ₄	0,35	-0,74	-0,71	-0,80	-0,83	-0,87	-0,87	-0,89	-0,90	-0,93	-0,90	0,89	0,47	-0,89	1,00	
SDD ₅	0,63	-0,71	-0,78	-0,80	-0,78	-0,76	-0,76	-0,77	-0,77	-0,79	-0,74	0,93	0,89	-0,84	0,81	1,00

A partir da análise de correlação entre as feições, identificou-se forte correlação negativa entre a transparência medida *in situ*, as bandas espectrais individuais do sensor MSI e a feição SDD_3 , que variou entre -0,41 e -0,62. Maiores correlações positivas podem ser observadas entre a transparência e as feições SDD_1 (0,51), SDD_2 (0,71) e SDD_5 (0,63). A feição SDD_4 também apresentou correlação positiva com o parâmetro (0,35).

A seleção de variáveis via *Knock-Out* foi aplicada utilizando todos os modelos e as oito campanhas de campo (Tabela 4.9). Os resultados apresentados apontam que as feições SDD_5 , SDD_3 , SDD_2 , B8 e B4 (respectivamente) são as feições de maior recorrência entre aquelas com melhor contribuição por campanha. Cabe lembrar que as três feições da literatura mais recorrentes neste ranqueamento utilizam a B4 e um deles utiliza, além da B4, a B8 na construção do seu modelo.

Tabela 4.9: Resultado da seleção de variáveis por *ranking* via *Knock-out* para SDD.

Estágio	Geral	r^2	01/07/2019	r^2	04/10/2019	r^2	31/05/2020	r^2	06/05/2021	r^2	20/06/2021	r^2	24/08/2021	r^2	23/09/2021	r^2	28/10/2021	r^2	
1	B12	0,88	B2		NaN	B6	0,94	B8A	0,96	B11	0,95	B4	0,93	B7	0,98	B5	0,99	B3	0,98
2	B8	0,88	B3		NaN	B8	0,94	B4	0,96	B7	0,95	B3	0,93	B11	0,98	B8A	0,99	B12	0,98
3	B7	0,88	B4		0,99	B4	0,95	B6	0,97	B6	0,95	B5	0,94	B8	0,98	B7	0,99	B6	0,98
4	B5	0,88	B7		0,99	B11	0,96	B12	0,97	B5	0,95	B12	0,94	B4	0,98	B12	0,99	B8	0,98
5	B3	0,88	B5		0,99	B5	0,96	B5	0,97	B3	0,95	B11	0,94	B8A	0,98	B3	0,99	B5	0,98
6	B11	0,88	B11		0,99	B7	0,97	B7	0,97	B8A	0,95	B8A	0,94	B12	0,98	B11	0,99	B11	0,98
7	B8A	0,88	B6		0,99	B8A	0,97	B8	0,97	B8	0,95	B8	0,95	B6	0,98	B6	0,99	B8A	0,98
8	B6	0,85	B12		0,98	B12	0,97	B11	0,97	B12	0,95	B7	0,95	B5	0,97	B2	0,99	B7	0,98
9	B4	0,85	B8A		0,97	B3	0,95	B3	0,96	B4	0,95	B6	0,94	B3	0,97	B4	0,97	B4	0,98
10	B2	0,65	B8		0,95	B2	0,78	B2	0,78	B2	0,93	B2	0,93	B2	0,94	B8	0,96	B2	0,94

No Estágio 1, todas as combinações possíveis de variáveis N-1 são realizadas eliminando a variável não incluída no melhor resultado. Repete-se o processo até que todas as variáveis tenham sido ranqueadas. O *ranking* final é apresentado em ordem decrescente.

Variação dos coeficientes

A Figura 4.19a apresenta a variação dos β para as variáveis independentes B4, B8, SDD_2 , SDD_3 e SDD_5 . Foram utilizados os 175 pontos amostrais das oito campanhas que mensuraram a transparência a água.

Os dados amostrados em campo variaram entre 160 cm e 599 cm com valor mediano de 290 cm e coeficiente de variação de 26,30%. Estes dados revelam baixa variabilidade entre os valores e transparência significativa da água.

Ao analisar as variáveis isoladamente, observa-se alta variabilidade do β , especialmente para a variável B8 seguida da variável B4. As variáveis provenientes da literatura apresentaram os coeficientes mais estáveis na análise da SDD. O detalhamento das variáveis SDD_2 , SDD_3 e SDD_5 pode ser observado na Figura 4.19b.

Modelo selecionado

Com base na análise dos dados e estabilidade dos modelos de SDD, as variáveis B4, B8, SDD_2 , SDD_3 e SDD_5 baseadas no sensor MSI/Sentinel-2 foram selecionadas de acordo com o seu comportamento em relação à transparência mensurada a fim de se verificar o desempenho entre os dados observados e os dados preditos. Os resultados das análises são apresentados na Tabela 4.10. Cada linha representa um conjunto de dados e a última linha mostra o coeficiente de variação (razão entre o desvio padrão e a média) dos pesos β da regressão.

Tabela 4.10: Resultados estatísticos da classificação de feições das melhores bandas especiais e dos diferentes índices de SDD indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação.

Campanha	ρ B4			ρ B8			SDD_2			SDD_3			SDD_5		
	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
Geral	0,51	218,42	7923	0,39	243,4	10539,9	0,95	70,84	45,12	0,82	131,62	603,1	0,94	76,11	132,631
01/07/2019	0,95	80,86	47335	0,95	75,2	93839	0,97	63,47	54,469	0,98	43,38	1102,8	0,98	48,31	161,219
04/10/2019	0,72	170,27	10984	0,75	159,4	18296	0,91	93,72	55,236	0,88	111,44	614,94	0,87	114,83	165,69
31/05/2020	0,61	195,61	13704	0,78	145,65	49454	0,93	77,80	50,854	0,87	112,02	772,47	0,95	69,23	134,067
06/05/2021	0,88	101,68	18301	0,82	124,03	51973	0,92	78,12	41,513	0,89	94,76	748,9	0,94	67,53	109,477
20/06/2021	0,95	71,8	24429	0,93	81,8	42557	0,96	61,08	50,332	0,98	35,66	802,06	0,96	64,17	150,063
24/08/2021	0,90	114,5	29930	0,92	104,77	62706	0,97	64,50	40,927	0,96	68,17	979,64	0,97	58,01	127,712
23/09/2021	0,94	48,83	3948,7	0,96	38,4	5666,4	0,97	33,55	44,472	0,96	37,96	329,88	0,95	43,7	148,706
28/10/2021	0,84	105,32	7918,7	0,75	131,42	10856	0,97	41,09	45,414	0,93	69,59	518,35	0,94	61,52	137,316
Coef. Var.	0,752			0,770			0,112			0,327			0,125		

Legenda:  $r^2 > 0,90$  $r^2 0,80-0,89$  $r^2 0,70-0,79$  $r^2 0,60-0,69$  $r^2 0,50-0,59$  $r^2 < 0,50$

Nota-se que as bandas únicas B4 e B8, apesar da contribuição de cada uma para a estimativa do parâmetro, não apresentam, sozinhas, bons valores de r^2 para todos os campos realizados. Os piores resultados, abaixo de 0,72, foram produtos dos campos de outubro/2019 e maio/2020, bem como para o conjunto total de dados (geral). De modo geral, esses modelos apresentaram alto coeficiente de variação dos β (0,752 para B4 e 0,770 para B8).

Os melhores resultados foram obtidos a partir das razões de banda estabelecidas nos modelos SDD_2 e SDD_5 . Ambas as variáveis fazem uso das bandas azul (B2) e vermelha (B4) na configuração

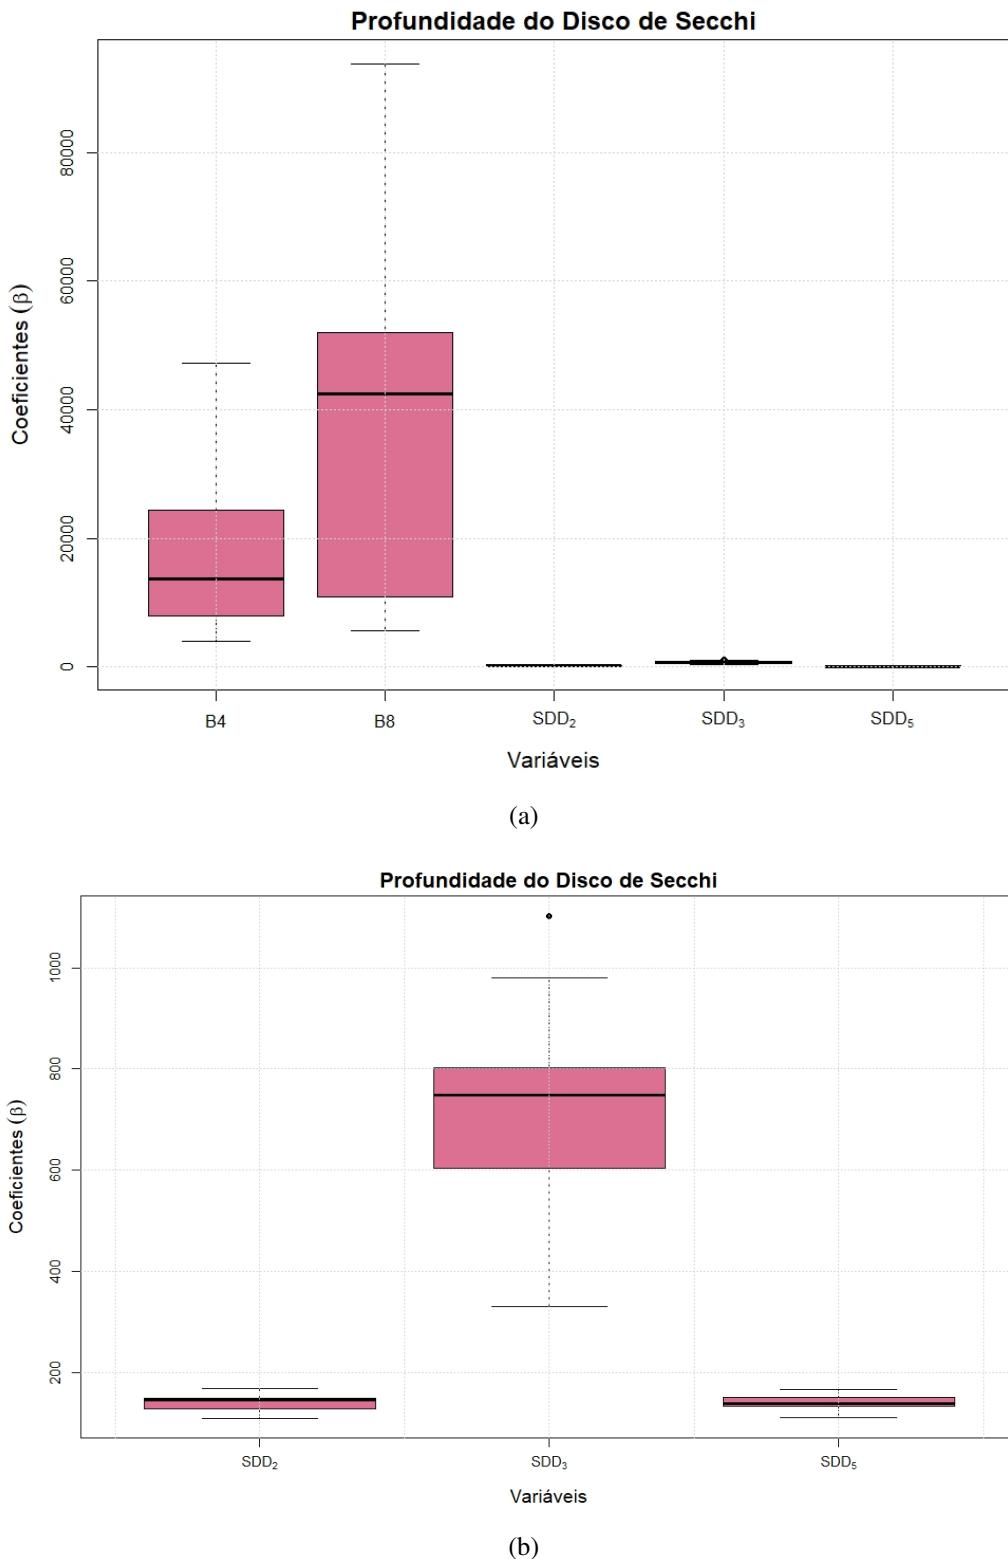


Figura 4.19: Variação dos coeficientes para SDD (a) e detalhamento da variação dos coeficientes para SDD para as variáveis SDD_2 , SDD_3 e SDD_5 (b).

de seus modelos. Na comparação campo a campo observa-se que os resultados apresentados pelos dois modelos foi bastante similar e o r^2 obtido foi significativo, superando 0,87 (para o campo de 04/10/2019) e, para o conjunto total de dados, superando 0,94. Mesmo sem calibração, os modelos podem ser considerados suficientemente estáveis, onde o coeficiente de variação dos pesos β produzidos foram 0,112 (SDD_2) e 0,125 (SDD_5).

Considerando a similaridade dos resultados e eficiência dos modelos, ambos foram selecionados para a etapa de validação a fim de verificar o desempenho desses modelos pós-calibração.

Validação do modelo

O modelo referente às variáveis SDD_2 e SDD_5 foram aplicados ao conjunto geral de dados. As Figuras 4.20 e 4.21 apresentam os valores dos dados amostrados *in situ* vs. os dados preditos pelo modelo selecionado. Por meio das imagens é possível identificar os erros mais significativos dos modelos. Os pontos são ilustrados em ordem crescente de acordo com a cronologia dos campos (sendo o primeiro em 01/07/2019 e o último em 28/10/2021).

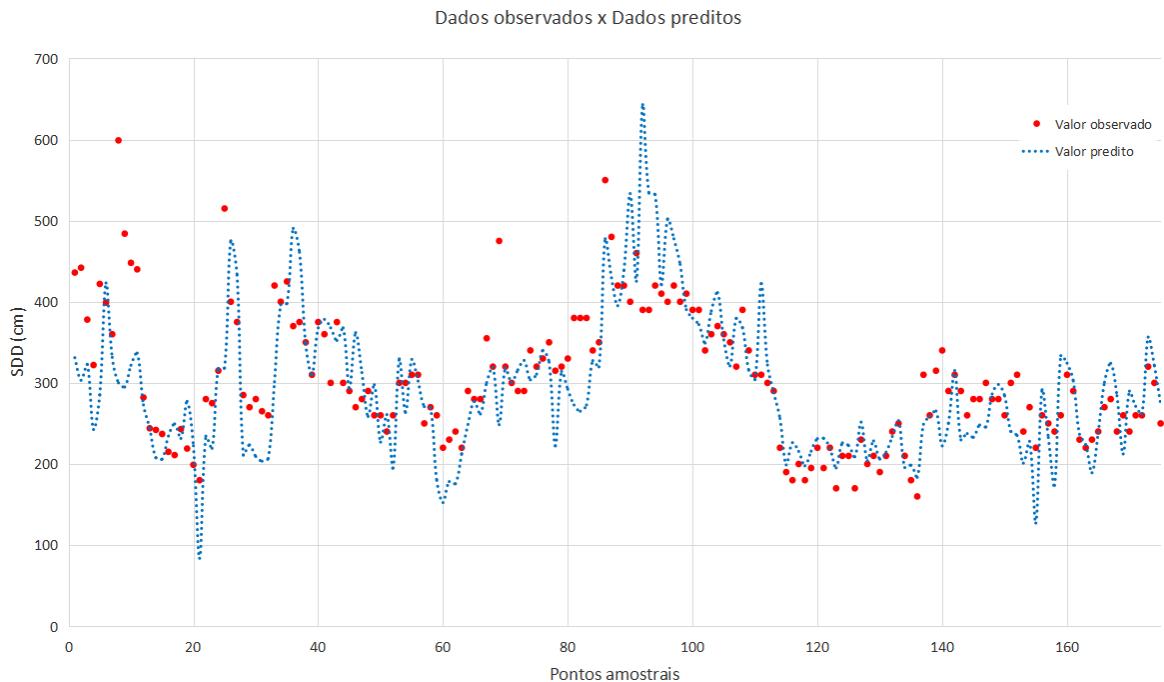


Figura 4.20: Dados observados *vs.* dados preditos utilizando o modelo SDD_2 para o conjunto geral de dados.

O gráfico ilustrado na Figura 4.20 apresenta os dados observados e preditos utilizando o modelo SDD_2 com o uso dos 175 pontos amostrados. O modelo, que utiliza as bandas B2, B4 e B8 apresenta bom ajuste dos dados em campos específicos, como em maio/2021, junho/2021 e agosto/2021. Os campos de julho/2019, outubro/2019 e setembro/2021 foram os campos com o menor ajuste dos dados. Em um contexto geral, os dados observados têm média de valores de 304,64 cm e os dados preditos, média de 293,71 cm.

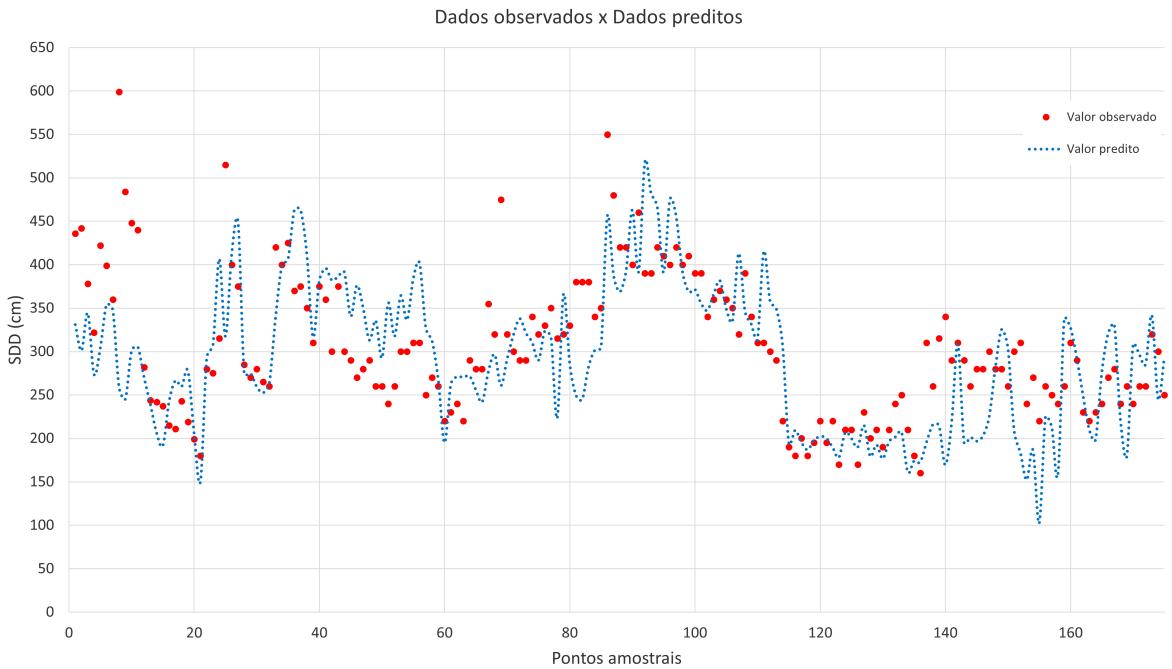


Figura 4.21: Dados observados *vs.* dados preditos utilizando o modelo SDD_5 para o conjunto geral de dados.

O modelo referente ao gráfico da Figura 4.21 mostra os dados observados e preditos utilizando o modelo SDD_5 fazendo uso do conjunto total de dados. O modelo, levemente mais simplório que o anterior, utiliza a razão de bandas $\frac{B4}{B2}$. Assim como no modelo SDD_2 , observa-se menor ajuste de dados nas duas primeiras campanhas (julho/2019 e outubro/2019), além da campanha de maio/2021. A média dos dados preditos com o modelo SDD_5 foi de 293,43 cm.

No modelo de regressão, o SDD_2 alcançou um $r^2 = 0,95$ enquanto o modelo SDD_5 alcançou um $r^2 = 0,94$, ambos com $p\text{-value} < 0,01$. Os gráficos ilustrando a equação e o resultado do desempenho entre os modelos e a transparência é apresentado na Figura 4.22 e 4.23. Nos dois casos valores mais altos de transparência refletem em maior dispersão e menor ajuste dos dados.

Com base nos resultados alcançados para o Reservatório de Três Marias e na similaridade do resultado geral dos dois modelos, a etapa de calibração foi efetuada observando o desempenho de cada um, campo a campo. Considerou-se dois pontos específicos do reservatório mensurados *in situ*, os mesmos pontos utilizados para a calibração do modelo de turbidez (um próximo ao barramento e outro nas proximidades da confluência entre os rios São Francisco e Paraopeba) por meio do uso do software livre [SIMOA SAT](#).

As Figuras 4.24 e 4.25 mostram os erros (diferença entre os valores medidos e observados) por pontos de amostragem em cada levantamento. Embora seja perceptível um erro significativo para o campo de outubro de 2019, observa-se, nitidamente, menor erro associado ao modelo SDD_2 se comparado ao SDD_5 . O modelo SDD_5 desempenhou baixíssima performance para os dois primeiros campos, que foram excluídos da análise.

A Tabela 4.11 mostra os erros obtidos calibrando os modelos selecionados utilizando dois pontos

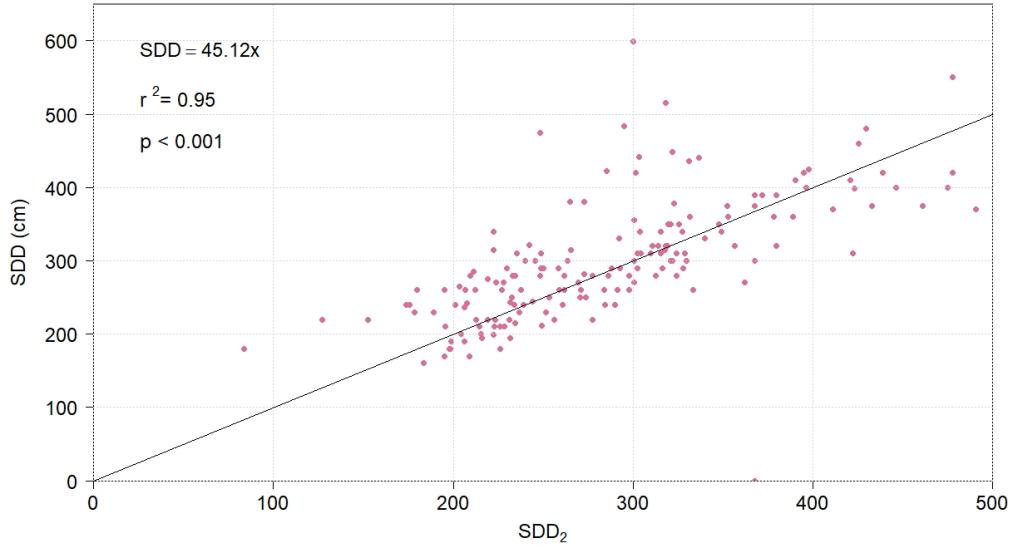


Figura 4.22: Modelo de regressão utilizando o modelo SDD_2 para o conjunto geral de dados sem calibração.

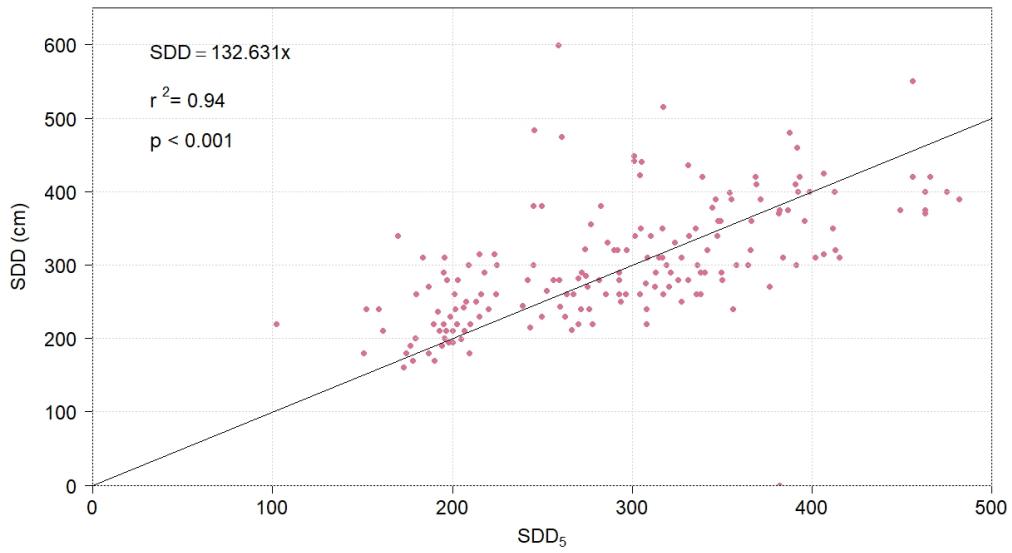


Figura 4.23: Modelo de regressão utilizando o modelo SDD_5 para o conjunto geral de dados sem calibração.

situados nas mesmas áreas (a jusante e a montante). A partir da análise da Tabela 4.11, observa-se que o modelo SDD_2 perdeu desempenho pós-calibração para os campos de julho/2019, outubro/2019 e agosto/2021. Os dois primeiros campos foram os campos com menor número de amostragem *in situ*, fator que pode ter impactado no resultado final do modelo. Para os demais campo, o erro não ultrapassou a marca de 60 cm. Já o modelo SDD_5 mostrou menor performance, especialmente no campo de outubro/2019, onde ele não conseguiu estimar a transparência a partir dos pontos amostrados. Para além, houve perda de desempenho nos campos de agosto/2021 e setembro/2021, com erro acima de 90 cm. Se comparados os resultados aplicados aos demais campos, o modelo SDD_5 foi inferior ao

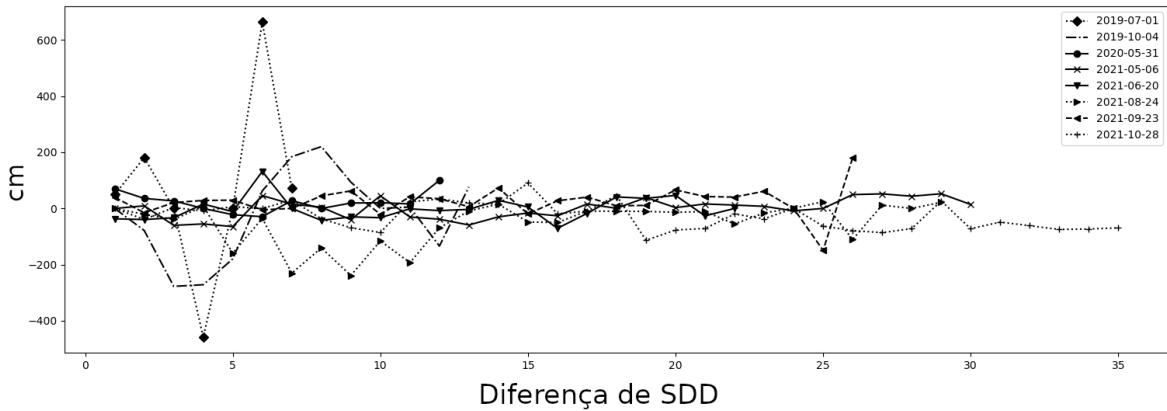


Figura 4.24: Gráfico mostrando a diferença entre a transparência medida e os valores obtidos pela calibração do modelo SDD_2 de dados Sentinel-2/MSI.

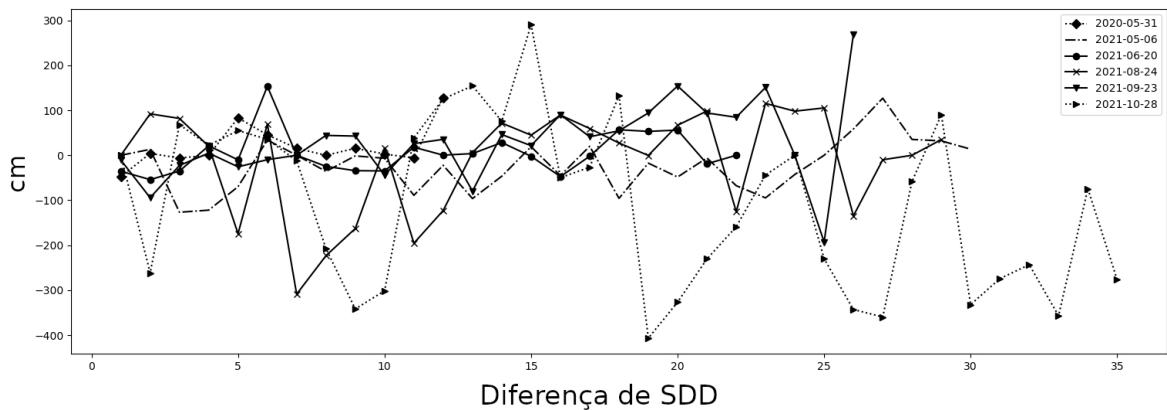


Figura 4.25: Gráfico mostrando a diferença entre a transparência medida e os valores obtidos pela calibração do modelo SDD_5 de dados Sentinel-2/MSI.

modelo SDD_2 , sendo este, então, descartado.

4.2.3 Concentração de chl-a

O *boxplot* na Figura 4.26 mostra o intervalo referente à obtenção da concentração de chl-a durante as sete campanhas de campo realizadas no reservatório.

Os menores valores de chl-a foram registrados na campanha de maio de 2020 e variaram entre 0,6 e 0,84 $\mu\text{g/L}$. Além de apresentar baixos valores, a campanha também foi caracterizada pela menor variabilidade da concentração no corpo d'água. O maior valor registrado refere-se à campanha de outubro/2019 onde a concentração de chl-a ultrapassou a marca de 8 $\mu\text{g/L}$. Observa-se também para esta campanha a maior oscilação da concentração do parâmetro (1,63 $\mu\text{g/L}$ – 8,1 $\mu\text{g/L}$).

De modo geral, é perceptível a baixa concentração de chl-a em todos os períodos onde houve mensuração do parâmetro. Em 88,5% dos pontos amostrados foram registrados índices de concentração menores do que 3 $\mu\text{g/L}$ e valores médios de 1,65 $\mu\text{g/L}$.

Tabela 4.11: RMSE e MAE obtidos para valores de SDD após calibração dos modelos SDD_2 e SDD_5 , respectivamente, usando dois pontos de medição *in situ*. A campanha de 28/10/2021 foi excluída pois não foram feitas mensurações próximas aos pontos adotados (montante/jusante).

SDD_2	01/07/2019	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021	Média
RMSE (cm)	314,1133	153,9670	40,9127	35,0563	41,3810	90,2459	58,0746	104,8215
MAE (cm)	203,4373	121,8004	30,6504	28,4420	29,9468	57,4971	41,0615	73,2622
SDD_5	01/07/2019	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021	Média
RMSE (cm)	31,0423	3332,0036	48,4749	60,5920	45,3882	114,2507	92,0886	531,9772
MAE (cm)	21,0054	2557,3554	29,4734	46,1855	31,3370	88,0784	66,6179	405,7219

Feições derivadas e avaliação da performance

A Figura 4.27 apresenta o comportamento espectral da chl-a no Reservatório de Três Marias de acordo com as bandas selecionadas do sensor MSI. Cabe ressaltar que, embora a banda 1 *coastal* (433 – 453 nm) possa ser importante para detecção de chl-a (e, eventualmente, turbidez) devido a sua boa penetração e proximidade a uma banda de absorção de clorofila (450 – 475 nm), sua baixa resolução de 60 m e problemas referentes a esta banda do sensor (Warren *et al.*, 2019) especialmente visível nesta banda foi um fator desmotivador para sua inclusão no estudo.

Para águas complexas continentais o uso das bandas do vermelho e do NIR podem ser eficazes na estimativa de chl-a devido à redução da interferência de outros parâmetros, como CDOM e material particulado não-algal nestas faixas espectrais, bem como o uso da razão entre o verde e o vermelho (ver Tópico 2.2.4). De acordo com a Figura 4.27 para o Reservatório de Três Marias, observa-se que a resposta espectral das bandas 3 e 2 são mais significativas em relação ao parâmetro, seguida da banda 4. As demais bandas do espectro (5, 6, 7, 8, 8A, 11 e 12) apresentam resposta similar entre elas, sendo menos significativas individualmente se comparadas às bandas do visível.

O comportamento espectral das demais feições selecionadas para o estudo ($Chla_1$, $Chla_2$, $Chla_3$, $Chla_4$, $Chla_5$, $Chla_6$ e $Chla_7$) podem ser observadas a partir da Figura 4.28. Assim como em turbidez e SDD, a figura retrata feições derivadas de estudos com foco na estimativa da qualidade da água presentes na literatura internacional cujas características dos corpos d’água selecionados se assemelham àquelas do Reservatório de Três Marias.

A partir da Figura 4.28 é possível observar comportamentos semelhantes entre as feições $Chla_1$, $Chla_5$ e $Chla_6$. Essas feições apresentam, em geral, comportamento linear de acordo com a resposta do sensor. Em contrapartida, as feições $Chla_3$, $Chla_4$ e $Chla_7$ também apresentam comportamento similar entre si, porém não-linear. As feições referentes aos modelos MCI e MPH ($Chla_3$ e $Chla_4$, respectivamente), em especial, indicam resposta muito semelhante e diferenciam-se, principalmente, pelo fator de escala -1000.

A Tabela 4.12 mostra os resultados da RLS entre as medições de chl-a e os dados de reflectância das 10 bandas do sensor MSI considerando o conjunto total de dados de chl-a (140 pontos). Como esperado, nenhuma regressão entre chl-a e uma única banda espectral produziu um forte r^2 . Os valores de r^2 mais significativos (0,46 – 0,57) foram obtidos com as três bandas do visível, principalmente pelo fato de que a radiação nessas bandas pode penetrar melhor na água. A B4 costuma responder

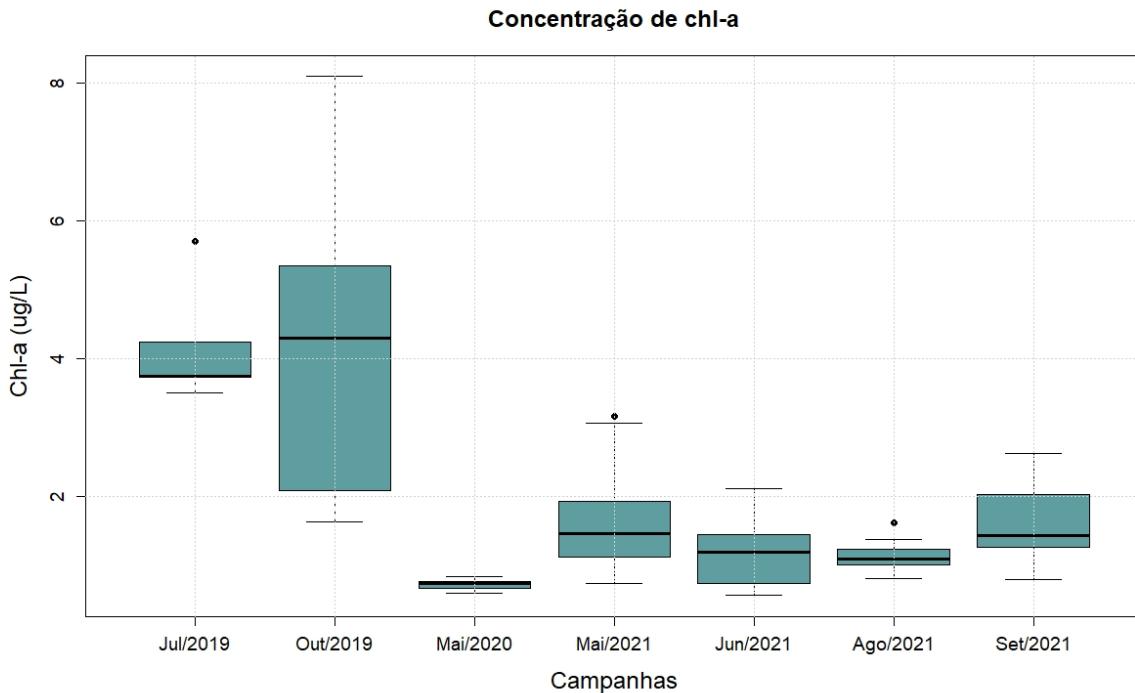


Figura 4.26: *Boxplot* da concentração de chl-a para as campanhas de campo.

bem a chl-a por ser uma banda de forte absorção, tanto de chl-a como de chl-b, sem sofrer interferências provenientes da atenuação atmosférica, o que afeta as bandas 1 e 2. As demais bandas do *red-edge*, NIR e SWIR produziram r^2 semelhantes entre 0,36 e 0,41.

Foram testados, ainda, os sete índices selecionados da literatura científica. É importante ressaltar que, embora tenham sido selecionados modelos cujos corpos d'água pudessem se assemelhar em algum aspecto ao Reservatório de Três Marias, os contextos ambientais podem ser bastante diferentes. Quatro desses índices produziram resultados de r^2 entre 0,60 ($Chla_2$ e $Chla_6$) e 0,64 ($Chla_5$) com o MCI ($Chla_3$) atingindo 0,63. Destaca-se o fato de que estes modelos tiveram um desempenho melhor do que qualquer uma das bandas espectrais testadas individualmente.

Seleção da feição

A fim de avaliar os efeitos da multicolinearidade em cada modelo e as correlações diretas entre as variáveis independentes foi gerada a matriz com o coeficiente de correlação de Pearson (Tabela 4.13). A Figura 4.29 representa as variáveis selecionadas graficamente.

Tabela 4.12: Performance da avaliação das feições individuais para chl-a.

ID	Feição	r^2	RMSE	MAE	p-value
$B2$	$\rho B2$	0,53	1,416	0,877	< 0,01
$B3$	$\rho B3$	0,57	1,346	0,840	< 0,01
$B4$	$\rho B4$	0,46	1,511	1,025	< 0,01
$B5$	$\rho B5$	0,41	1,589	1,112	< 0,01
$B6$	$\rho B6$	0,36	1,651	1,179	< 0,01
$B7$	$\rho B7$	0,37	1,638	1,164	< 0,01
$B8$	$\rho B8$	0,36	1,654	1,184	< 0,01
$B8A$	$\rho B8A$	0,36	1,647	1,191	< 0,01
$B11$	$\rho B11$	0,37	1,638	1,201	< 0,01
$B12$	$\rho B12$	0,37	1,642	1,189	< 0,01
$Chla_1$	$\frac{\rho B4}{\rho B8}$	0,42	1,568	0,938	< 0,01
$Chla_2$	$\frac{\rho B2}{\rho B3}$	0,60	1,305	0,816	< 0,01
$Chla_3$	$MCI = \rho B5 - 1005 [\rho B4 + \frac{(\rho B6 - \rho B4) * (B5 - B4)}{B6 - B4}]$	0,63	1,254	0,782	< 0,01
$Chla_4$	$MPH = \rho B5 - \rho B4 - \frac{(\rho B8A - \rho B4) * (B5 - B4)}{B8A - B4}$	0,46	1,513	1,029	< 0,01
$Chla_5$	$\frac{\rho B5}{\rho B4}$	0,64	1,240	0,784	< 0,01
$Chla_6$	$\rho B5 + (\frac{\rho B6}{\rho B4})$	0,60	1,298	0,829	< 0,01
$Chla_7$	$\rho B5 - (\frac{\rho B4 + \rho B6}{2})$	0,49	1,473	0,965	< 0,01

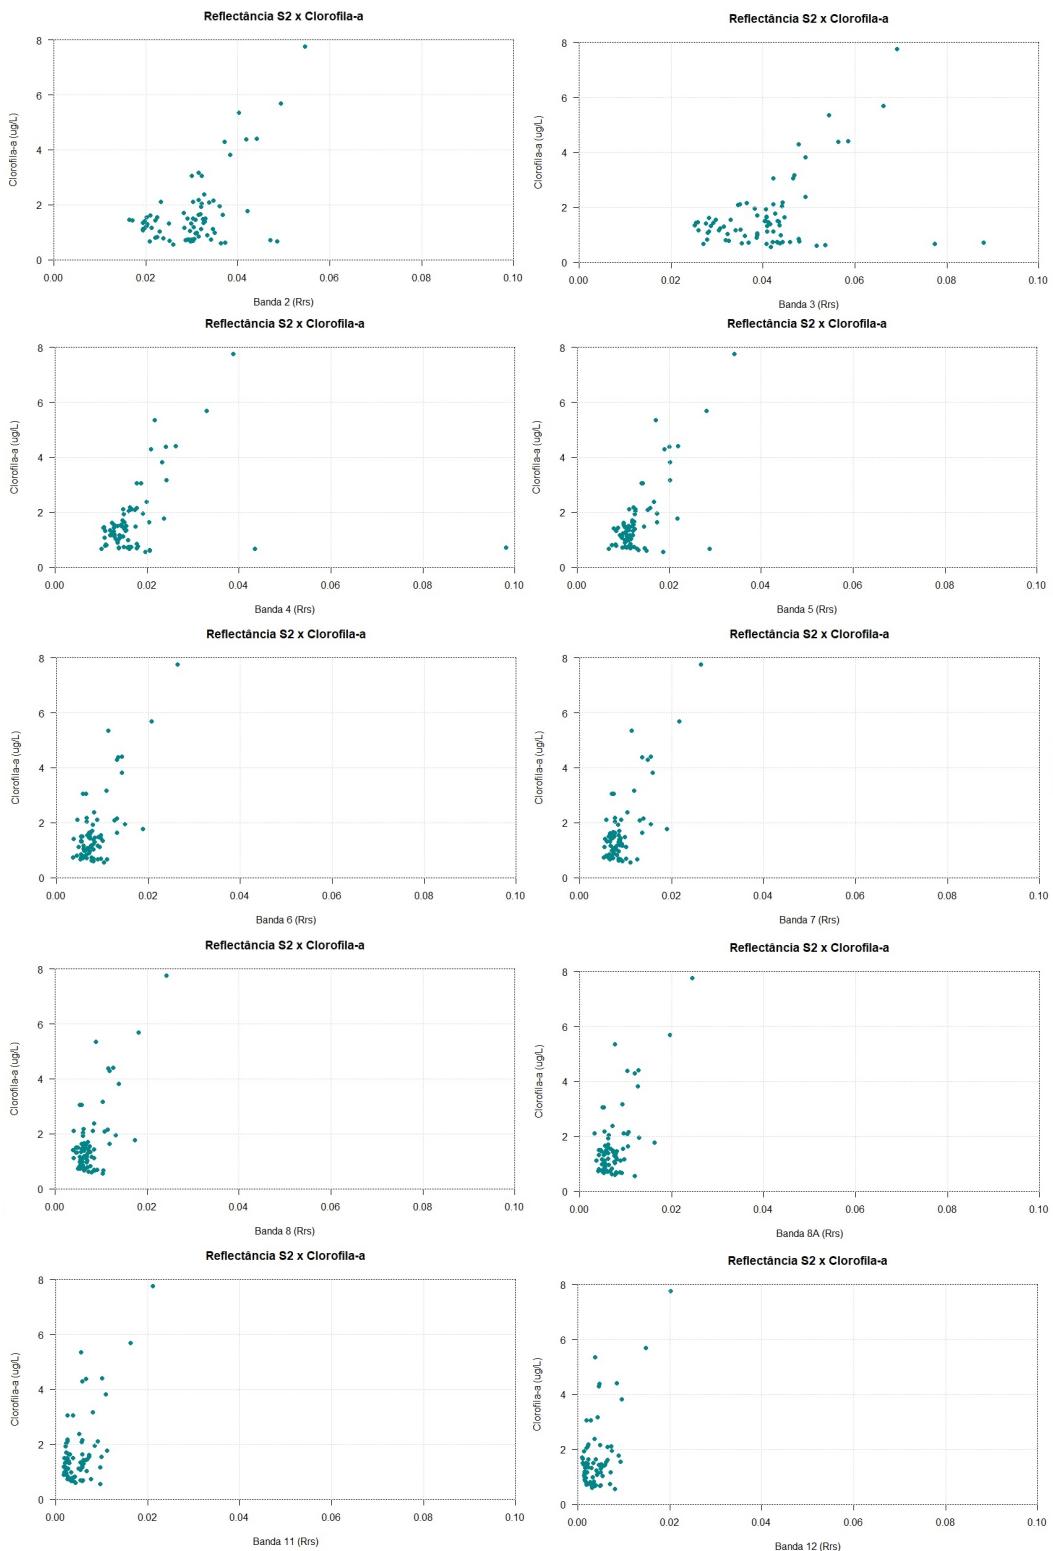


Figura 4.27: Relação entre concentração de chl-a e reflectância espectral do sensor MSI/Sentinel-2 no Reservatório de Três Marias.

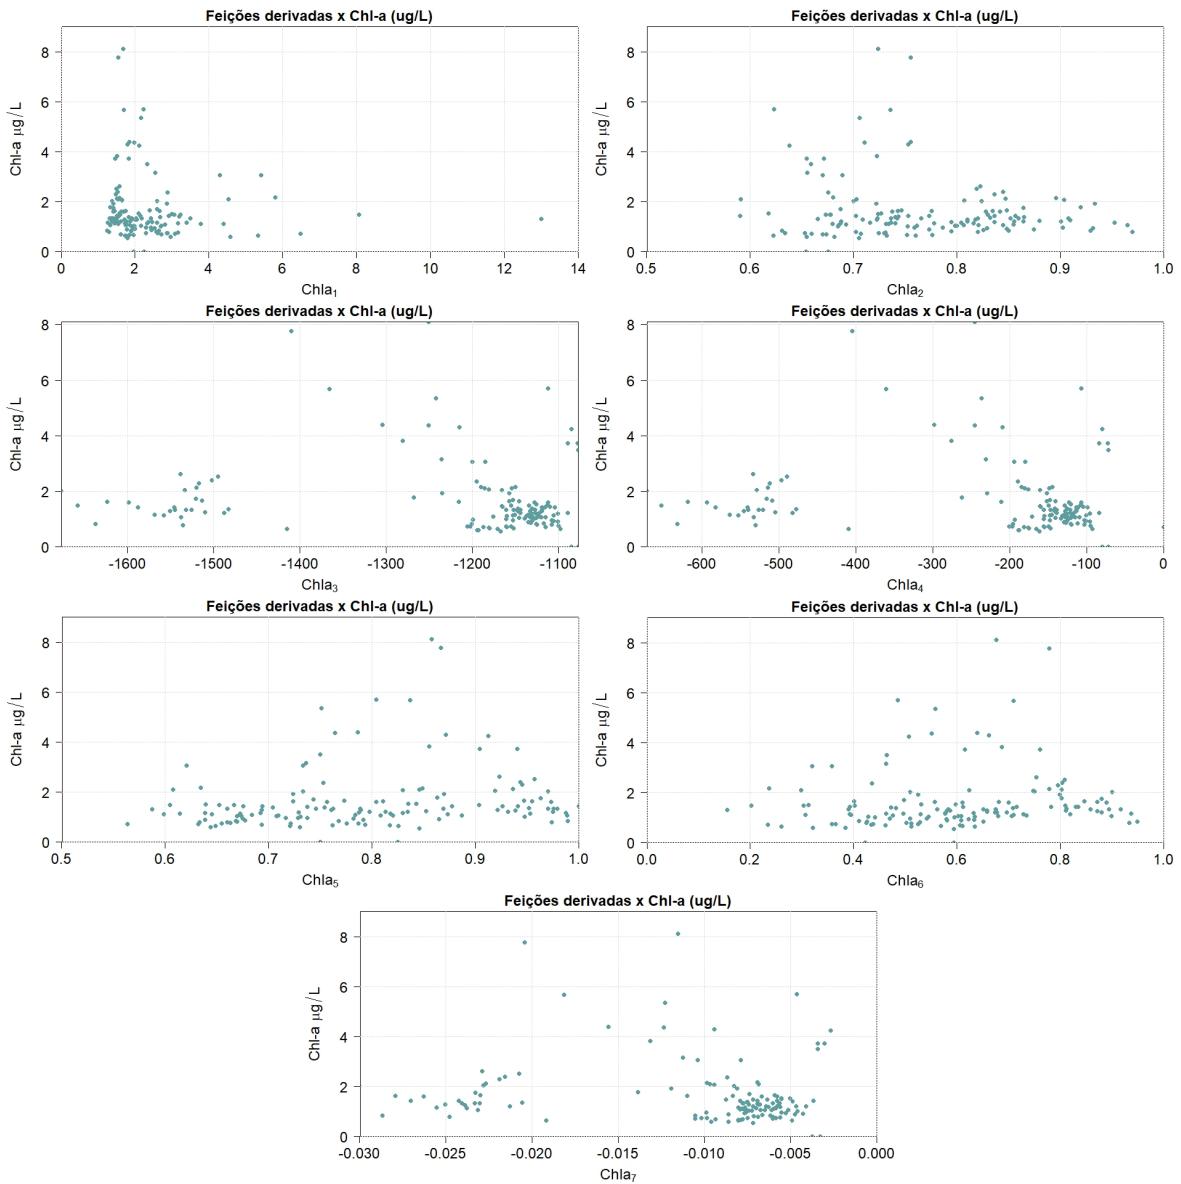


Figura 4.28: Relação entre chl-a e feições derivadas dos modelos da literatura no Reservatório de Três Marias.

Tabela 4.13: Matriz de correlação para chl-a.

Chl-a($\mu g/L$)	Chl-a($\mu g/L$)	B2	B3	B4	B5	B6	B7	B8	B8A	B11	B12	Chla ₁	Chla ₂	Chla ₃	Chla ₄	Chla ₅	Chla ₆	Chla ₇
1																		
B2	0,09	1																
B3	0,14	0,97	1															
B4	0,12	0,98	0,97	1														
B5	0,11	0,98	0,95	0,99	1													
B6	0,10	0,96	0,92	0,97	0,99	1												
B7	0,11	0,96	0,92	0,97	0,99	0,99	1											
B8	0,11	0,96	0,91	0,97	0,98	0,99	0,99	1										
B8A	0,12	0,94	0,90	0,96	0,98	0,99	0,99	0,99	1									
B11	0,15	0,86	0,82	0,90	0,92	0,94	0,94	0,94	0,95	1								
B12	0,15	0,81	0,77	0,85	0,87	0,89	0,89	0,90	0,91	0,98	1							
Chla ₁	-0,08	-0,26	-0,18	-0,28	-0,33	-0,39	-0,39	-0,41	-0,42	-0,45	-0,43	1						
Chla ₂	-0,15	0,50	0,34	0,45	0,48	0,54	0,54	0,54	0,53	0,45	0,42	-0,38	1					
Chla ₃	-0,12	-0,98	-0,97	-1	-0,99	-0,97	-0,97	-0,97	-0,96	-0,90	-0,85	0,28	-0,41	1				
Chla ₄	-0,13	-0,98	-0,97	-0,99	-0,99	-0,97	-0,97	-0,97	-0,96	-0,90	-0,85	0,29	-0,45	0,99	1			
Chla ₅	0,18	0,61	0,54	0,65	0,71	0,74	0,75	0,76	0,77	0,74	0,62	0,40	-0,65	-0,65	1			
Chla ₆	0,11	0,63	0,52	0,65	0,71	0,77	0,76	0,77	0,79	0,76	0,72	0,64	-0,65	-0,65	0,86	1		
Chla ₇	-0,12	-0,98	-0,97	-0,99	-0,98	-0,96	-0,96	-0,95	-0,88	-0,83	0,27	-0,47	0,99	0,99	-0,59	-0,64	1	

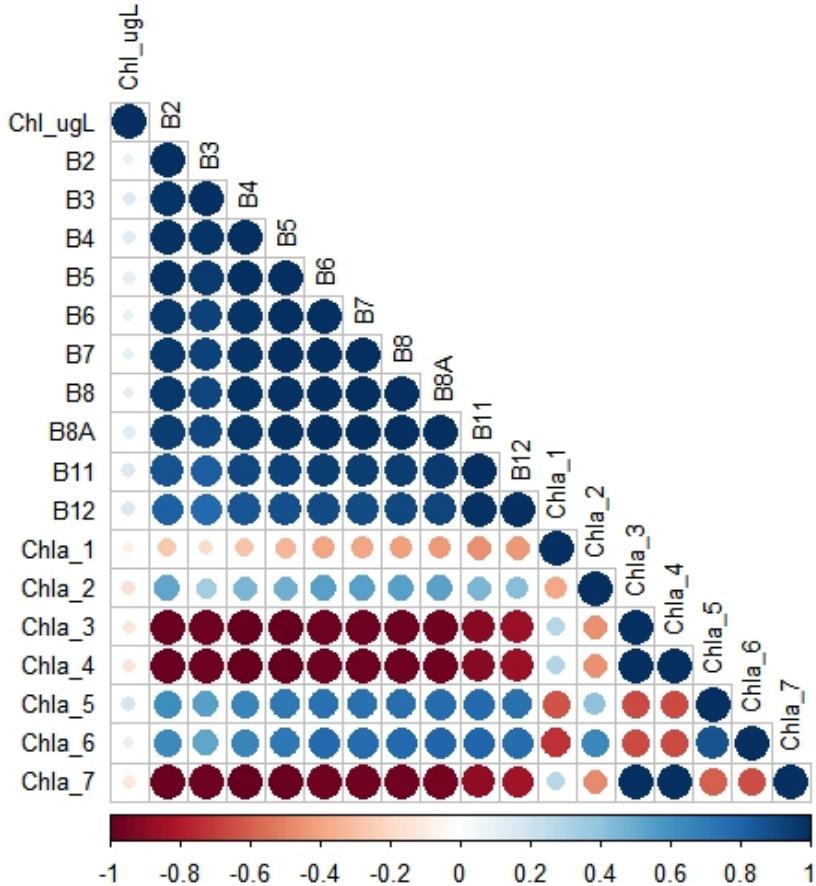


Figura 4.29: Gráfico da matriz de correlação para chl-a.

Verifica-se a partir dos resultados da matriz de correlação uma forte correlação negativa para as feições *Chla₃*, *Chla₄* e *Chla₇* com relação às bandas espectrais do sensor MSI e uma forte correlação positiva entre as feições *Chla₂*, *Chla₅* e *Chla₆*. A feição *Chla₁* apresentou correlação negativa média comparada às bandas espectrais. No entanto, é interessante observar a baixa correlação com a chl-a, tanto para as bandas espectrais quanto para os índices selecionados da literatura científica.

Uma RLM foi então aplicada a todas as bandas espectrais para determinar as melhores combinações, bem como as bandas com maior impacto nos modelos por meio do algoritmo *Knock-Out*. A Tabela 4.14 mostra os resultados dessas operações para o conjunto de total de dados, bem como para as campanhas individuais.

Tabela 4.14: Resultado da seleção de variáveis por ranking via Knock-out para chl-a.

Estágio	Geral	r^2	01/07/2019	r^2	04/10/2019	r^2	31/05/2020	r^2	06/05/2021	r^2	20/06/2021	r^2	24/08/2021	r^2	23/09/2021	r^2
1	B8	0,65	B2	NaN	B3	0,96	B6	0,97	B8A	0,95	B7	0,84	B11	0,96	B3	0,95
2	B11	0,65	B3	NaN	B12	0,96	B7	0,97	B3	0,95	B6	0,85	B4	0,96	B8	0,95
3	B4	0,66	B4	NaN	B8	0,96	B8A	0,98	B8	0,95	B12	0,85	B12	0,96	B11	0,95
4	B12	0,66	B12	NaN	B11	0,96	B11	0,98	B5	0,95	B11	0,85	B5	0,97	B2	0,95
5	B7	0,66	B11	0,99	B6	0,95	B12	0,98	B12	0,95	B5	0,86	B8A	0,97	B7	0,96
6	B6	0,66	B5	0,88	B2	0,95	B3	0,98	B11	0,95	B3	0,86	B3	0,97	B8A	0,95
7	B2	0,67	B6	0,90	B8A	0,95	B4	0,98	B2	0,95	B8	0,86	B8	0,97	B4	0,95
8	B8A	0,64	B7	0,79	B4	0,95	B8	0,97	B6	0,94	B4	0,86	B7	0,97	B12	0,95
9	B5	0,62	B8	0,75	B7	0,92	B5	0,96	B7	0,93	B2	0,85	B6	0,97	B6	0,95
10	B3	0,57	B8A	0,74	B5	0,85	B2	0,91	B4	0,91	B8A	0,85	B2	0,96	B5	0,88

No Estágio 1, todas as combinações possíveis de variáveis N-1 são realizadas eliminando a variável não incluída no melhor resultado. Repete-se o processo até que todas as variáveis tenham sido ranqueadas. O ranking final é apresentado em ordem decrescente.

É interessante observar que o r^2 permanece em níveis relativamente semelhantes entre as dez bandas ou uma única banda, em especial para as campanhas de campo individuais. Outro aspecto relevante é que a banda mais significativa (última remanescente) é majoritariamente B3 (aparecendo três vezes entre os resultados) e B5 (duas vezes). Todos os quatro modelos de banda incluem uma banda visível e a maioria inclui uma banda do *red-edge*. Por outro lado, o conjunto total de dados produziu apenas um modelo razoável com a maioria das bandas do MSI. Além disso, cabe ressaltar que a classificação das bandas espectrais varia amplamente.

Dando importância aos dados analisados, bem como a melhor resposta dos modelos da literatura na estimativa da chl-a, as variáveis $Chla_2$, $Chla_3$, $Chla_5$ e $Chla_6$ foram consideradas para a seleção do modelo final.

Variação dos coeficientes

A Figura 4.30 mostra a variação dos β para cada variável selecionada calculada isoladamente utilizando todas as campanhas onde houve mensuração da concentração de chl-a. Observa-se que os β de cada índice selecionado não ultrapassam o valor de 6, com especial atenção ao índice $Chla_3$ que apresenta baixíssimo valor de β (entre -1,34e-03 e -6,10e-04). No entanto, a variação dos coeficientes para os índices $Chla_2$, $Chla_5$ e $Chla_6$ ainda assim são aceitáveis pois encontram-se na faixa de valores daqueles obtidos para chl-a com r^2 da ordem de, aproximadamente, 0,60 para todos.

Modelo selecionado

A partir da análise dos resultados conclui-se que, mesmo em um ambiente aquático relativamente estável, nenhum modelo único fornece boas estimativas em todos os contextos. Nesse sentido, os índices de chl-a importados da literatura são, provavelmente, opções melhores, uma vez que oferecem resultados relativamente estáveis em todas as oito campanhas, conforme sugerido pelos resultados na Tabela 4.12. Conforme os testes, para ambientes aquáticos em estado ultraoligotrófico a oligotrófico, os índices $Chla_2$, $Chla_3$, $Chla_5$ e $Chla_6$ apresentam melhor potencial para a estimativa do parâmetro.

A Tabela 4.15 mostra as pontuações desses mesmos quatro índices de chl-a junto com os RMSEs e os pesos β que resultaram de regressões. A última linha mostra o coeficiente de variação dos pesos β .

Os resultados, de modo geral, foram bastante próximos entre as campanhas. O menor desempenho foi atribuído, invariavelmente, ao conjunto de dados total e à campanha de 01/07/2019. Nas ocasiões, o valor de r^2 situou-se entre 0,60 e 0,66, enquanto o RMSE ficou entre 1,240 e 2,056 $\mu\text{g/L}$. Os modelos responderam melhor à campanha de 24/08/2021, onde o r^2 superou 0,96 com RMSE abaixo de 0,205 $\mu\text{g/L}$.

Via de regra, dentre os testes realizados, o melhor modelo para estimativa da concentração de chl-a foi o índice $Chla_5$. Observa-se que, além de apresentar as melhores estatísticas, o modelo exibiu baixo coeficiente de variação dos β entre todas as campanhas.

Esses coeficientes são ainda maiores que os obtidos para a turbidez (ver Tabela 4.5) e, embora a

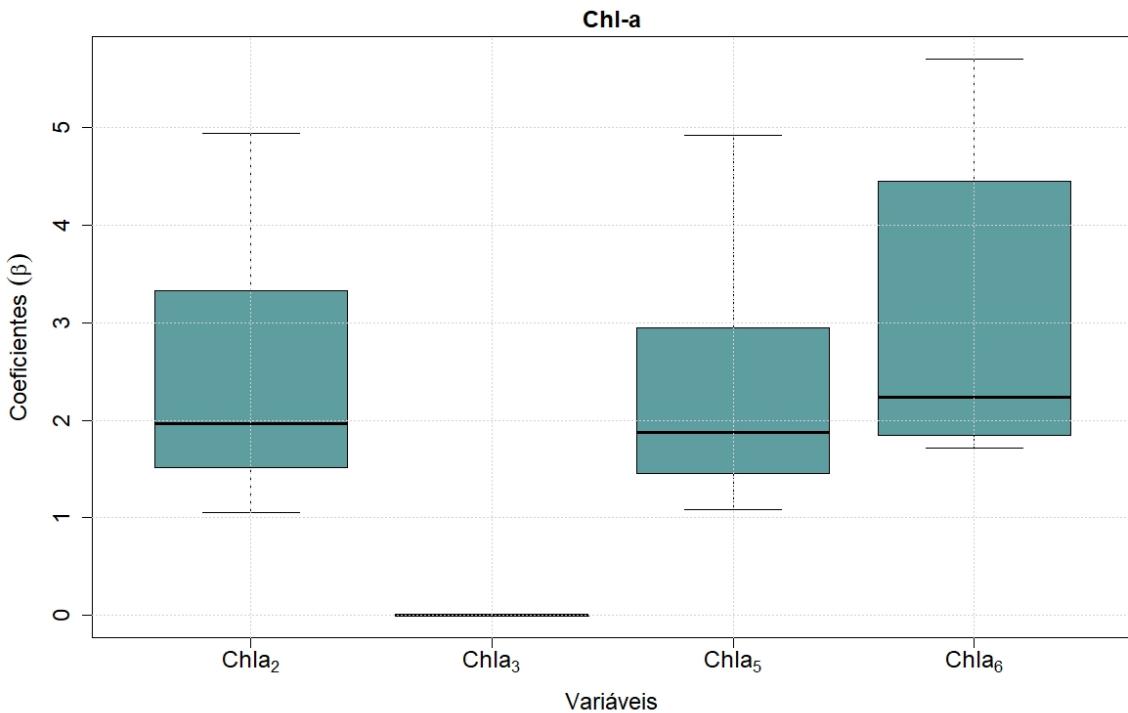


Figura 4.30: Variação dos coeficientes para chl-a.

maioria dos valores r^2 esteja acima de 0,80, nenhum desses índices podem ser usados diretamente para fornecer boas estimativas numéricas de concentração de chl-a (assim como para turbidez). Esta observação deve ser considerada em um contexto onde todas as medições *in situ* foram adquiridas com uma sonda multiparâmetros de última geração (calibrada) em um intervalo menor do que quatro horas das imagens de satélite, todas sem nuvens e corrigidas para efeitos atmosféricos com um algoritmo de eficácia comprovada (MAJA). Ou seja, apesar das condições ambientais e técnicas aplicadas ao mesmo corpo d'água serem iguais, os modelos apresentam uma variabilidade da ordem de duas a três vezes os valores referentes à concentração real de chl-a.

Validação do modelo

O modelo referente ao índice *Chla₅* foi aplicado ao conjunto geral de dados. A Figura 4.31 apresenta os valores dos dados amostrados *in situ* vs. os dados preditos pelo modelo selecionado.

Observa-se que o índice representado pelo modelo *Chla₅* gerou valores de chl-a, principalmente, entre 1 e 2 $\mu\text{g/L}$ para os 140 pontos amostrais. Os valores observados com concentração acima de 2 $\mu\text{g/L}$ ou abaixo de 1 $\mu\text{g/L}$ não foram estimados de forma significativa e adequada à realidade do reservatório durante as campanhas. As maiores concentrações de chl-a, obtidas nas duas primeiras campanhas (01/07/2019 e 04/10/2019) foram as menos representativas dentre as demais. A média observada na primeira campanha foi de 2,99 $\mu\text{g/L}$ enquanto a média predita foi de 1,76 $\mu\text{g/L}$. Já na segunda campanha, a média observada foi ainda maior, sendo de 4,11 $\mu\text{g/L}$ contra 1,74 $\mu\text{g/L}$ para os dados preditos.

Tabela 4.15: Resultados estatísticos entre as medidas de chl-a e os índices de chl-a indicando o r^2 , os pesos β e o RMSE de cada modelo. A última linha mostra o coeficiente de variação dos β .

Campanha	<i>Chla₂</i>			<i>Chla₃</i>			<i>Chla₅</i>			<i>Chla₆</i>		
	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
Geral	0,60	1,305	2,1057	0,63	1,254	-1,34E-03	0,64	1,240	2,0888	0,60	1,298	2,6067
01/07/2019	0,61	2,056	4,516	0,64	1,987	-0,002761	0,66	1,923	3,603	0,63	2,018	5,319
04/10/2019	0,70	2,424	4,9346	0,79	1,983	-0,0032969	0,77	2,121	4,9234	0,73	2,296	5,7035
31/05/2020	0,98	0,081	1,05418	0,97	0,100	-6,10E-04	0,98	0,096	1,08377	0,95	0,142	1,7139
06/05/2021	0,82	0,712	2,137	0,86	0,611	-1,39E-03	0,85	0,644	2,3012	0,77	0,803	3,5766
20/06/2021	0,87	0,422	1,6536	0,89	0,396	-1,03E-03	0,89	0,389	1,4105	0,89	0,388	1,872
24/08/2021	0,96	0,205	1,3723	0,97	0,173	-1,00E-03	0,97	0,181	1,49822	0,96	0,197	1,85989
23/09/2021	0,88	0,549	1,8252	0,90	0,505	-1,02E-03	0,90	0,512	1,6571	0,87	0,566	1,8314
Coef. Var.	-0,593			-0,611			0,563			0,535		

Legenda:  $r^2 > 0,90$  $r^2 0,80-0,89$  $r^2 0,70-0,79$  $r^2 0,60-0,69$

O modelo de regressão referente ao índice selecionado *Chla₅* alcançou um $r^2 = 0,64$, RMSE = 1,240 $\mu\text{g/L}$ e p -value < 0,01. O gráfico ilustrando a equação e o resultado do desempenho entre o modelo e a chl-a é apresentado na Figura 4.32. Observa-se que, assim como para turbidez, quanto maiores os valores de chl-a, maior a dispersão e menor ajuste dos dados.

Conforme anteriormente visto e comprovado a partir das análises desenvolvidas, ao utilizar dados não calibrados para o reservatório em questão não é possível obter um resultado suficiente por meio da análise de regressão. O método de calibração para os dados de chl-a, assim como os demais, também consistiu no emprego de dois pontos (a jusante e a montante) para cada campanha de campo. A Figura 4.33 mostra os erros (diferença entre os valores medidos e observados) por pontos de amostragem em cada levantamento. A Tabela 4.16 mostra os erros obtidos após o processo de calibração.

Tabela 4.16: RMSE e MAE obtidos para valores de chl-a após calibração do índice *Chla₅* usando dois pontos de medição *in situ*.

Chl-a	01/07/2019	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021	Média
RMSE ($\mu\text{g/L}$)	2,1621	2,5476	0,2480	0,8452	0,5056	0,3953	0,9947	1,1000
MAE ($\mu\text{g/L}$)	1,4673	1,7343	0,1916	0,6275	0,4003	0,2965	0,7445	0,7803

4.3 Análise da dinâmica espacial da turbidez, transparência e chl-a no Reservatório de Três Marias

A análise temporal dos parâmetros estudados é essencial para compreender as variações e os processos que ocorrem em ecossistemas aquáticos. Esses parâmetros são fundamentais para compreender fatores como a produtividade biológica, processos de sedimentação e transporte de material particulado, além de influenciarem a disponibilidade de luz e nutrientes para os organismos aquáticos.

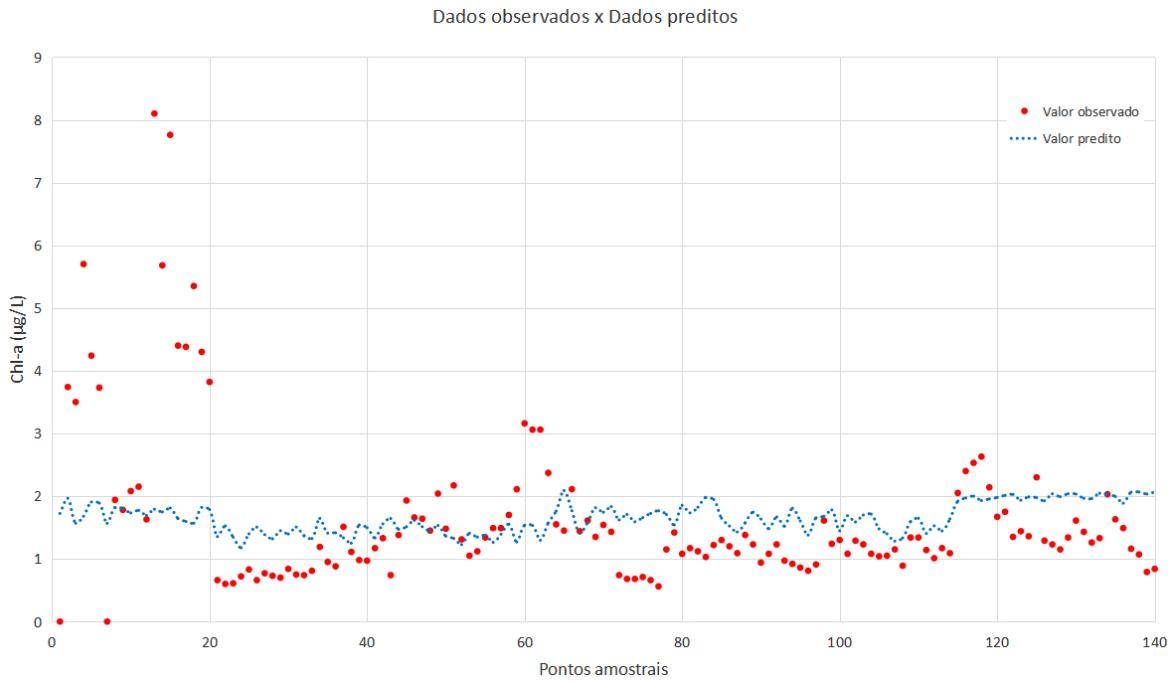


Figura 4.31: Dados observados *vs.* dados preditos utilizando o índice $Chla_5$ para o conjunto geral de dados sem calibração.

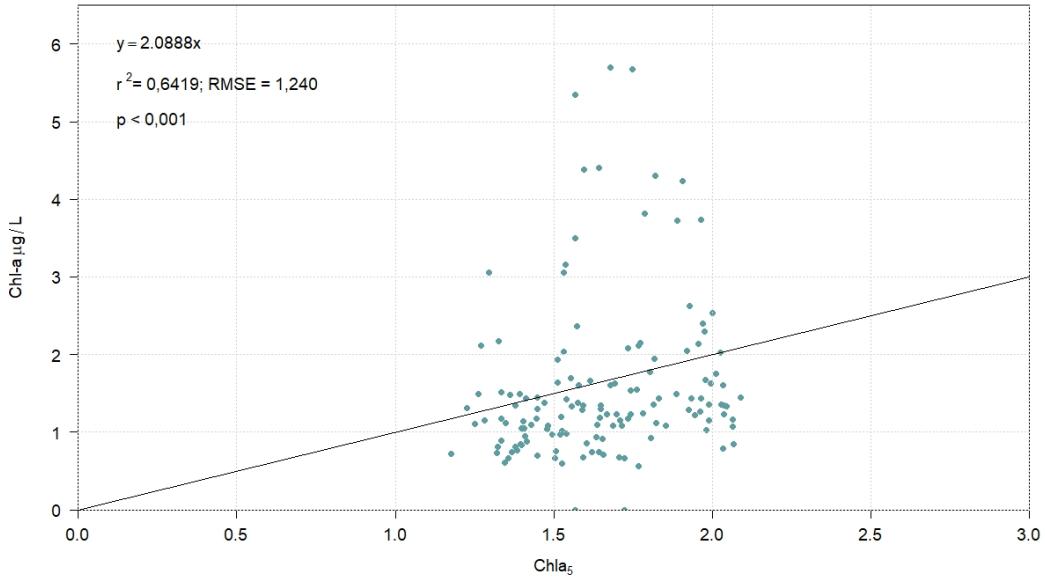


Figura 4.32: Modelo de regressão utilizando o índice $Chla_5$ para o conjunto geral de dados sem calibração.

Além das amostragens representativas e calibração adequada dos equipamentos de medição, a análise deve considerar fatores ambientais e sazonais. O objetivo deste tópico é buscar compreender o rela-

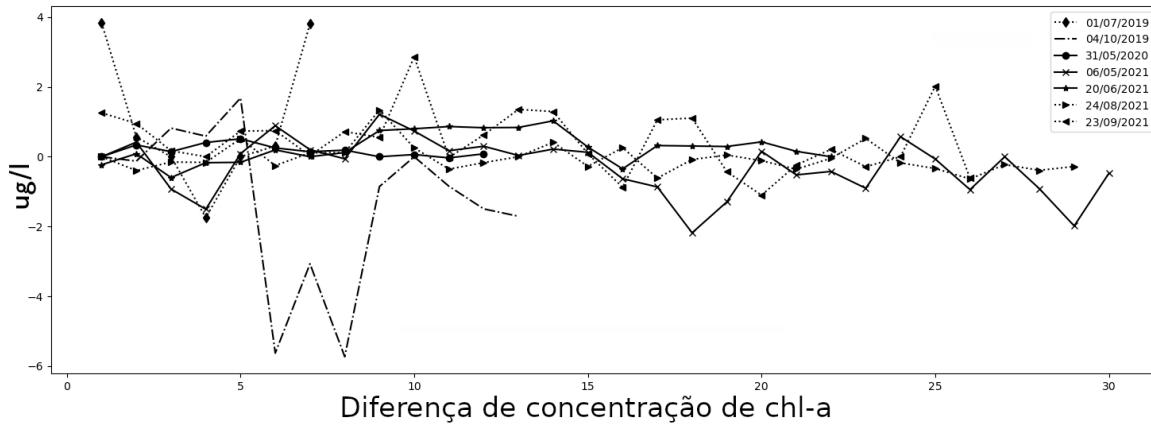


Figura 4.33: Gráfico mostrando a diferença entre as concentrações medidas de chl-a e os valores obtidos pela calibração dos índices de dados Sentinel-2/MSI.

cionamento entre os parâmetros estudados no espaço e no tempo no Reservatório de Três Marias.

Como visto anteriormente, o aumento da biomassa fitoplânctônica pode causar alterações na qualidade da água, como a diminuição da transparência e o aumento da turbidez. Águas mais turvas, devido à concentração de material suspenso, pode influenciar a transparência da água devido à redução da sua capacidade de transmitir a luz, sendo inversamente proporcional à turbidez.

Os modelos gerados e calibrados para turbidez (*NLTDI*), transparência (*SDD₂*) e chl-a (*Chla₅*) foram aplicados aos mapas de cada campanha de campo, o que permitiu analisar cada parâmetro ao longo do tempo. As Figuras 4.34, 4.35 e 4.36 ilustram a variação de turbidez, transparência e chl-a, respectivamente, no Reservatório de Três Marias de acordo com as campanhas realizadas.

Conforme discutido ao longo do trabalho, a campanha referente ao mês de maio/2020 apresentou comportamento inverso às demais campanhas para os parâmetros turbidez e transparência. Acredita-se que a coincidência com o início do período pandêmico de COVID-19 e a consequente subutilização do reservatório (entre outros potenciais aspectos) possam ter influenciado nos resultados obtidos. De acordo com a espacialização dos dados refletida nos mapas observa-se que a qualidade da água do reservatório na data citada é inferior nas proximidades do barramento e superior na porção central da represa. Com relação à chl-a, o mês de maio/2020 indicou aumento da concentração na porção central do reservatório e afluentes. O menor índice de chl-a nesta data está situado próximo à barragem.

Os resultados indicam que, nas proximidades do barramento, a baixa turbidez coincide com a alta transparência nas datas correspondentes. Nas campanhas de outubro/2019, maio/2021, junho/2021, agosto/2021 e outubro/2021 a turbidez do reservatório chegou próxima do limite de detecção da sonda apresentando valores entre 0 e 2 FNU. A SDD, para as mesmas datas, revelou valores de transparência elevados, chegando a alcançar quase 10 m de profundidade. O contrário também é perceptível, em especial, para as campanhas de junho/2021 e setembro/2021, onde os maiores índices de turbidez e mais baixa transparência da água se concentram na porção sul (à montante) do reservatório.

Quanto à chl-a, percebe-se consistentemente valores de concentração mais altos nas regiões próximas às aglomerações de parques de piscicultura e de fazendas (em Morada Nova de Minas,

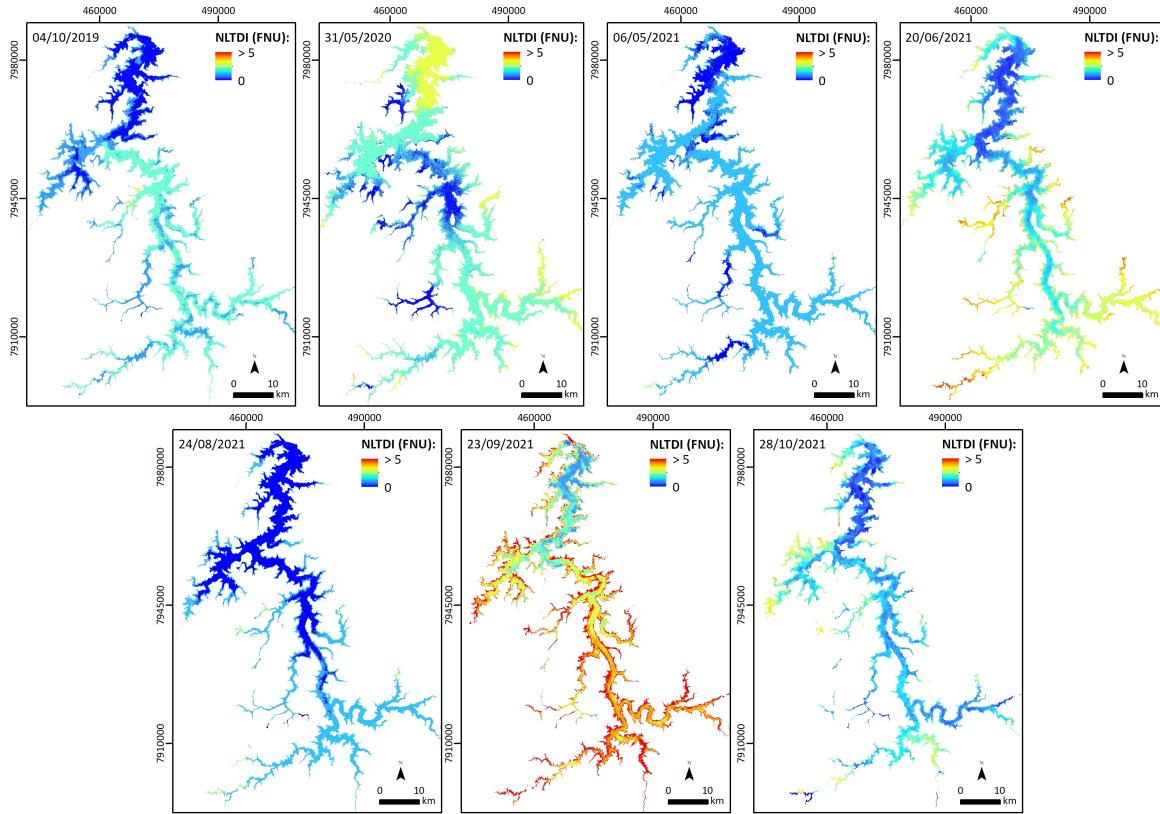


Figura 4.34: Mapas de turbidez das campanhas de campo utilizando o índice NLTDI calibrados em dois pontos.

especialmente no Rio Indaiá, e em toda porção central). A acumulação de nutrientes provinda de atividades de piscicultura e agricultura/pecuária podem ser fatores explicativos para maior concentração de chl-a nesta região. No entanto, os valores para este parâmetro podem ser considerados baixos, como ilustra a aplicação do modelo *Chla₅* na Figura 4.36.

No geral, analisando visualmente os mapas simulados a partir dos modelos obtidos, a tendência da dinâmica espacial no Reservatório de Três Marias é de melhor qualidade da água nas proximidades da barragem e util decréscimo da qualidade no sentido à montante da represa e nos afluentes do Rio São Francisco. Sabe-se que determinados estados tróficos nas proximidades de tomadas d'água podem prejudicar a operação de sistemas de captação, o que demanda constante monitoramento e obriga melhor qualidade da água nestes setores independente do uso ao qual o reservatório é destinado (Vilela, 2010). Ainda assim, os resultados obtidos comprovam, mais uma vez, que este ambiente aquático apresenta boa qualidade (considerando os três parâmetros estudados). São águas que variaram de claras a moderadamente claras com alta transparência, baixa turbidez e baixa concentração de chl-a durante todo o período da pesquisa.

É importante ressaltar que a relação entre a clorofila-a, turbidez e transparência da água pode variar de acordo com as características específicas de cada ecossistema. Em corpos d'água naturalmente ricos em matéria orgânica, por exemplo, a relação entre clorofila-a e turbidez pode ser mais complexa devido à interação entre os diferentes tipos de partículas suspensas. Essas informações são essenciais

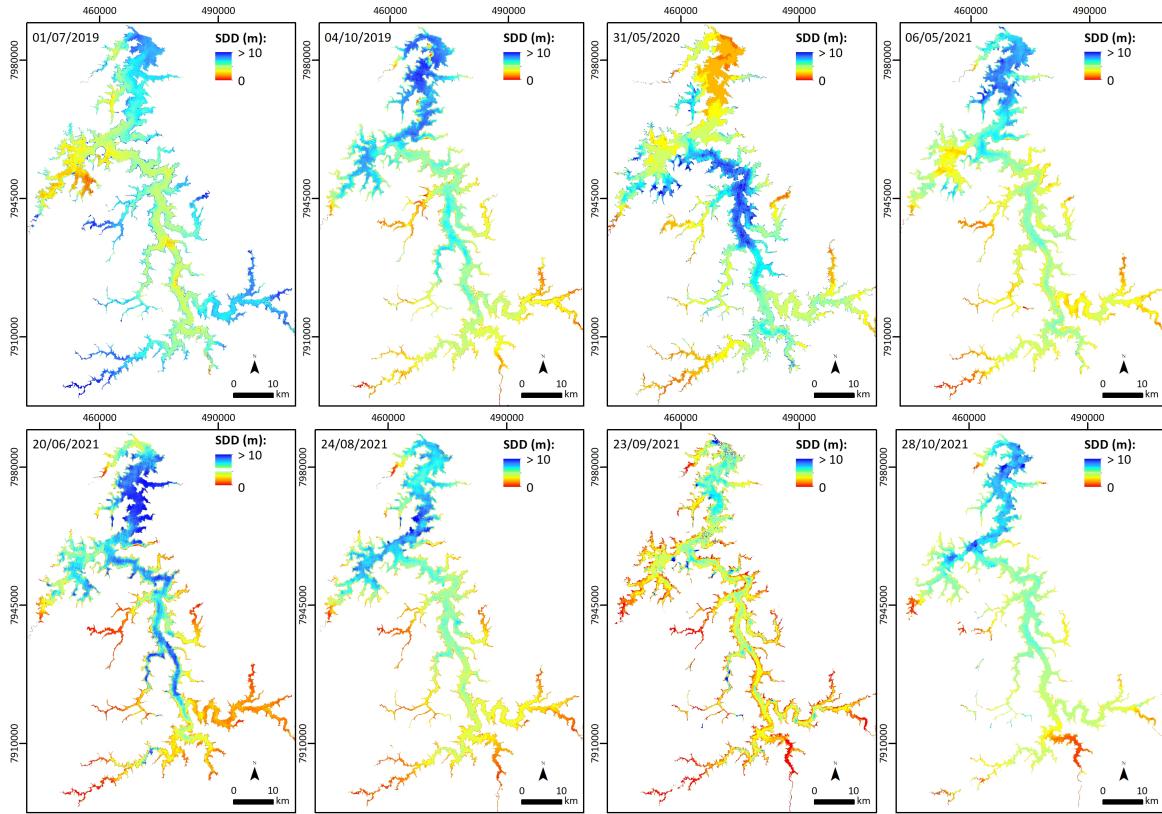


Figura 4.35: Mapas de SDD das campanhas de campo utilizando o modelo SDD_2 calibrados em dois pontos.

para a gestão e conservação dos recursos hídricos e para a tomada de decisões em relação ao manejo dos ecossistemas aquáticos.

4.4 Replicação da abordagem proposta: Reservatório Várzea das Flores

Para testar a abordagem proposta foram adquiridos dados de qualidade da água de outro ambiente aquático. O local selecionado foi o Reservatório Várzea das Flores, situado entre os municípios de Contagem e Betim, a 40 km da capital Belo Horizonte (Minas Gerais). O barramento forma um ambiente aquático de aproximadamente $5,2 \text{ km}^2$, profundidade média de 8,4 m e profundidade máxima registrada de 22,8 m ([Pedra, 2014](#)).

Embora seja um reservatório de abastecimento de água (ao contrário de hidrelétricas como Três Marias), sua qualidade é inferior aparentando ser constantemente mesotrófico. Foi realizada uma amostragem *in situ* em 30 de junho de 2022 que revelou valores de turbidez de até 14 FNU, transparência mínima de 50 cm e concentrações de chl-a de, aproximadamente, 7 $\mu\text{g/L}$.

A Tabela 4.17 mostra os valores de r^2 juntamente com os erros RMSE e MAE obtidos, primeiramente, por meio de regressão linear simples entre os valores *in situ* de turbidez, SDD e chl-a e os

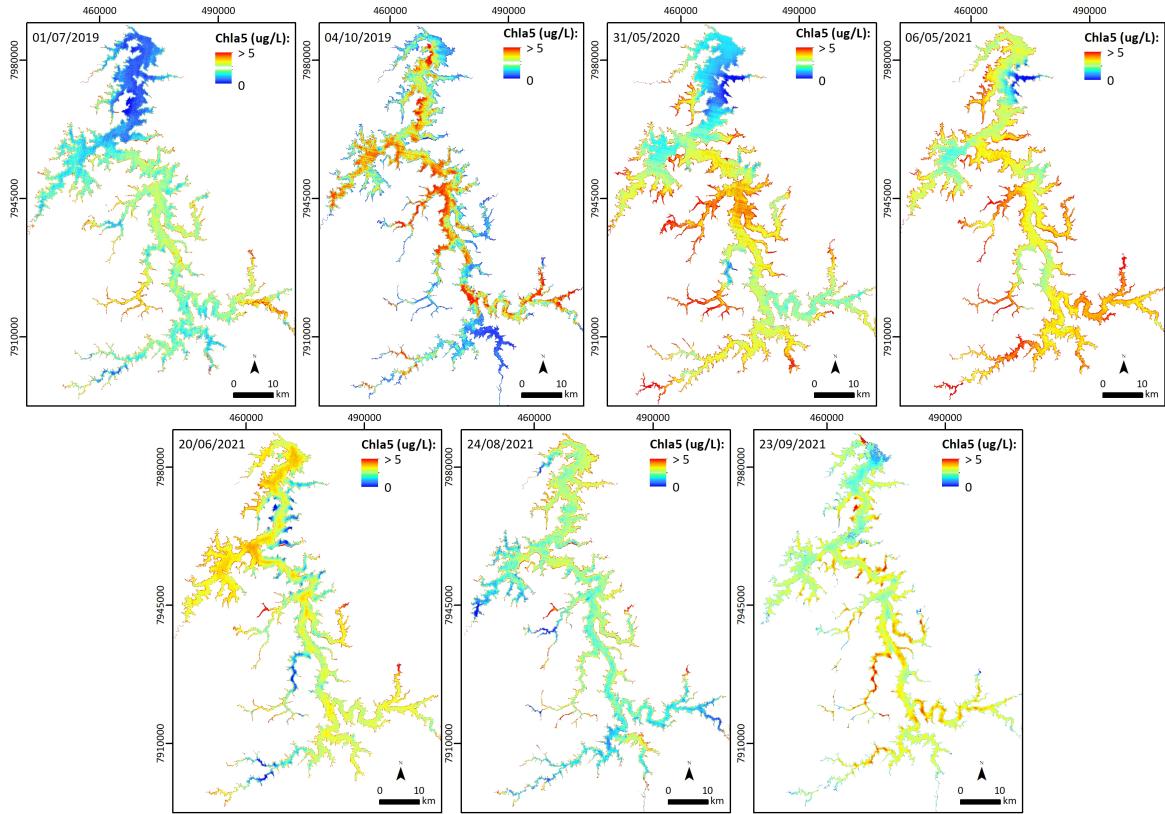


Figura 4.36: Mapas de chl-a das campanhas de campo utilizando o índice $Chla_5$ calibrados em dois pontos.

índices de turbidez (NLTDI), SDD (SDD_2) e chl-a ($Chla_5$). A coluna à direita mostra os resultados da regressão aplicando a calibração de dois pontos antes do processo. Observa-se que os erros da calibração de dois pontos são menores se comparados a regressão direta.

Cabe ressaltar que os métodos empregados nesta pesquisa, bem como os resultados obtidos, são diretamente associados ao Reservatório de Três Marias e replicados no Reservatório Várzea das Flores com suas características ópticas próprias.

A Figura 4.37 apresenta o resultado dos mapas de turbidez, SDD e chl-a no Reservatório Várzea das Flores após a calibração dos modelos em dois pontos do ambiente aquático.

Tabela 4.17: Comparação entre aplicação da regressão linear e calibração em dois pontos no Reservatório Várzea das Flores.

Índice		Regressão linear	Regressão linear pós calibração em dois pontos
Turbidez $\frac{(B3-B2)}{(B3+B2)}$	r^2	0,611	0,628
	RMSE	6,1688	2,4616
	MAE	1,4389	1,5005
Secchi SDD_2	r^2	0,945	0,976
	RMSE	188,5005	31,5218
	MAE	181,4114	24,8259
Chl-a $Chla_5$	r^2	0,479	0,807
	RMSE	4,6309	0,7820
	MAE	1,9937	0,5857

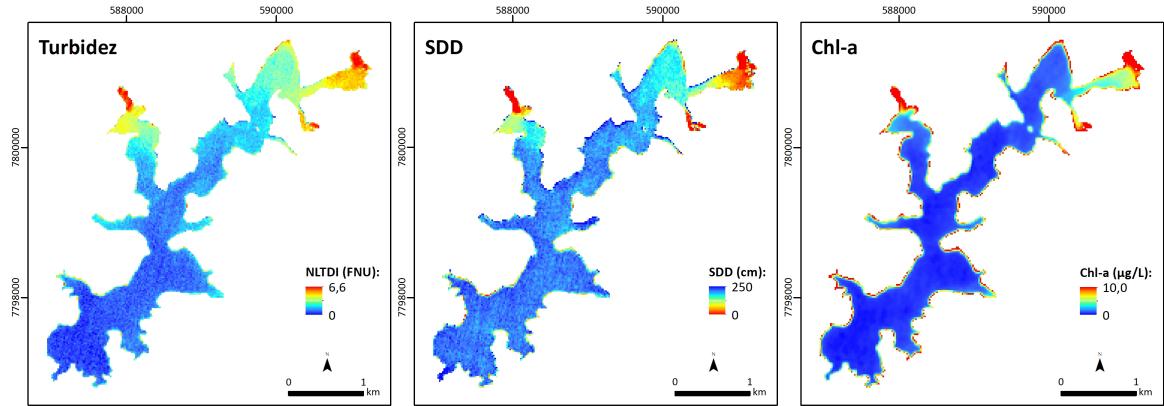


Figura 4.37: Mapas de turbidez, SDD e chl-a no Reservatório Várzea das Flores. Os mapas foram produzidos usando os índices calibrados de dois pontos NLTDI, SDD_2 e $Chla_5$.

Capítulo 5

CONSIDERAÇÕES FINAIS

O RESERVATÓRIO de Três Marias, de acordo com o Índice de Estado Trófico, é um ambiente de produtividade primária praticamente nula sendo classificado como um reservatório ultraoligotrófico a oligotrófico. Além do baixo grau de trofia, este ambiente aquático apresenta, de modo geral, alta transparência da água e, consequentemente, baixa turbidez.

A baixa variação dos valores dos parâmetros no reservatório foi constatada a partir dos dados analisados das sete campanhas de campo realizadas somadas a uma campanha realizada pelo Instituto Nacional de Pesquisas Espaciais, todas efetuadas entre os anos de 2019 e 2021, além da análise de outros dados de monitoramento obtidos desde 2016 *in situ*. Os baixos valores de clorofila-a e turbidez associados à alta transparência da água representaram um grande desafio na pesquisa proposta, uma vez que o volume de estudos publicados nas literaturas nacional e internacional que tratam ambientes de águas claras opticamente complexas ainda é baixo.

Por um lado, as amostragens realizadas *in situ* forneceram dados pontuais acerca dos parâmetros ópticos de qualidade da água que permitiram a calibração ajustada dos modelos, porém impossibilitaram a compreensão total da variabilidade espacial do reservatório. Sob outra perspectiva, os dados provenientes das imagens de satélite permitiram a compreensão da dinâmica espacial do reservatório. No entanto, as imagens limitam-se a responder de maneira mais eficaz apenas às propriedades ópticas da água.

A análise dos resultados obtidos respondeu de forma significativa à hipótese do trabalho. É possível caracterizar a concentração de clorofila-a, turbidez e transparência da água utilizando técnicas de sensoriamento remoto em ambientes de águas claras a moderadamente claras de forma sistemática. As imagens de satélite de alta resolução (10 m / 30 m) são disponibilizadas gratuitamente e os satélites têm frequência de revisita podendo ir de 5 (Sentinel-2) a 8 dias (Landsat-8 / Landsat-9), permitindo a aquisição instantânea de dados em territórios de grande extensão geográfica.

Neste trabalho buscou-se encontrar uma maneira eficaz de transformar os dados do sensor Sentinel-2 em estimativas de turbidez, transparência e concentrações de clorofila-a com a melhor precisão usando abordagens empíricas. Em particular, buscou-se determinar quais bandas espectrais ou índices eram as mais promissores para um corpo d'água com condições ultraoligotróficas a oligotróficas. O objetivo também foi condicionado pela definição de um método operacional utilizável pelos órgãos

gestores dos reservatórios. Para este objetivo, foi proposto que, utilizando-se apenas os dados Sentinel-2, a melhor abordagem, então, consiste em calibrar os dados com duas medições *in situ* em lados opostos da faixa dinâmica (ou próximos a ela).

Após a análise de todos os resultados verificou-se que as estimativas de turbidez e transparência são mais simples e, geralmente, mais precisas em relação à concentração de clorofila-a. Foi criado um índice de diferença normalizada para águas de baixa turbidez (NLTDI) utilizando as bandas verde e azul do Sentinel-2, uma vez que foi comprovado o aumento da reflectância do verde em relação ao azul neste tipo de ambiente. Para a transparência, dois modelos que utilizam as bandas azul, vermelho e infravermelho próximo do Sentinel-2 proveram bons resultados, com atenção especial à razão entre o azul e o vermelho, onde o erro associado a este modelo foi significativamente menor do que aquele que utiliza as três bandas. Para clorofila-a, três índices forneceram estimativas razoáveis de concentração, incluindo o Índice Máximo de Clorofila (MCI) e a razão simples entre as bandas do *red-edge* e vermelha ($\frac{\rho B5}{\rho B4}$).

Observou-se que os valores de r^2 são consideravelmente reduzidos quando os modelos são construídos com o conjunto de dados total que inclui pesquisas diferentes realizadas ao longo dos anos do estudo. Foi comprovado que nenhum modelo de turbidez, transparência ou clorofila-a é robusto o suficiente para ser aplicado diretamente a outros corpos d'água ou em datas diferenciadas sem ajuste de regressão ou calibração. Com isso, uma abordagem de calibração de dois pontos foi proposta para gerar estimativas precisas com logística reduzida.

É suposto que os modelos executados neste estudo sejam aplicáveis a outros sistemas aquáticos com características ópticas semelhantes. Os modelos empregados no Reservatório Várzea das Flores, cujo aspecto se assemelha ao Reservatório de Três Marias, gerou bons resultados fazendo uso dos índices propostos e da abordagem de calibração em dois pontos.

É importante ressaltar que o monitoramento ambiental aquático por sensoriamento remoto não substitui as medições periódicas que devem ser realizadas *in situ*, porém ele pode ser considerado um indicador para potenciais anomalias existentes no reservatório, bem como para o acompanhamento da dinâmica temporal do corpo hídrico. Conforme ressaltado, atualmente as medições dos parâmetros são pontuais, realizados de maneira esporádica no tempo e, em geral, são pouco representativas da extensão do reservatório. Além disso, as amostragens *in situ* demandam uma logística complexa, onerosa e necessitam de equipamentos sofisticados e igualmente expansivos. O sensoriamento remoto e as tecnologias relacionadas a ele possibilitaram a análise imediata dos parâmetros ópticos da água abordados no Reservatório de Três Marias e oferecem grande perspectiva de uso operacional em sistemas lênticos com características semelhantes à esta represa.

5.1 Sugestões para trabalhos futuros

Sabe-se que modelos empíricos raramente podem ser exportados para outras áreas de estudo. No entanto, os resultados encontrados pela execução da metodologia no Reservatório de Várzea das Flores encorajam a replicação do método. O Sentinel-2 provou ter um sensor capaz de estimar a qualidade da água pelos parâmetros turbidez, transparência e clorofila-a. Embora o Reservatório

de Três Marias tenha apresentado concentrações de sólidos suspensos totais, ficocianina e CDOM abaixo do limite de detecção em algumas campanhas, sugere-se que parâmetros opticamente ativos diferentes dos processados aqui possam ser estimados a partir da aptidão do sensor MSI para tal uso em ambientes aquáticos semelhantes à Três Marias do ponto de vista óptico.

As principais limitações do sensoriamento remoto aquático para estimativa da qualidade da água, bem como aplicado a outras áreas, ainda estão ligadas às condições climáticas. Períodos úmidos, névoas densas e alta concentração de nuvens inviabilizam o uso da técnica, por serem muito atenuados por esses elementos, e não permitem a identificação e leitura do ambiente por meio de imagens. Grande volumes de chuva podem carrear para o reservatório partículas de sedimentos que tendem a influenciar na turbidez e na transparência da água. Sugere-se que, imediatamente após os períodos de chuva e nebulosidade, realize-se medições dos parâmetros da água *in situ*, calibração dos modelos e avaliação da acurácia destes.

Os últimos anos têm trazido grandes inovações nos sensores ópticos dos satélites. Supõe-se que este fato aliado ao grande volume de missões futuras possa agregar maior precisão aos resultados, uma vez que resoluções mais finas (espacial, espectral, temporal e/ou radiométrica) e sensores dedicados aos estudos aquáticos têm sido lançados, muitos com disponibilidade gratuita e facilidade de acesso.

O uso sistemático de novas plataformas, como o *Google Earth Engine*, e a integração de dados de fontes variadas (Landsat, Aster, Sentinel-2, Sentinel-3, entre outras) podem ser capazes de melhorar as estimativas dos parâmetros ópticos de qualidade da água. Sugere-se que, além do uso de tais dados, seja feito o acréscimo de outras variáveis como precipitação, evaporação e volume de água.

Conforme afirmado no capítulo anterior, os métodos empregados nesta pesquisa, bem como os resultados obtidos, são diretamente associados ao Reservatório de Três Marias e replicados no Reservatório Várzea das Flores com suas características ópticas próprias. Para que a abordagem utilizada neste trabalho seja aplicada em outros corpos d'água com propriedades ópticas distintas é necessário reavaliar o método a cada etapa e valida-lo ao fim do processo.

Finalmente, este trabalho tem, também, a intenção de auxiliar gestores públicos e privados nas políticas ambientais e gestão do reservatório. A metodologia sugere o estabelecimento de pontos de monitoramento fixos e estratégicos para calibração das estimativas provenientes dos dados de satélite visando menor custo e resposta objetiva da dinâmica deste recurso hídrico a partir dos pontos representativos.

REFERÊNCIAS

- Abdelmalik, K. W. (2018). Role of statistical remote sensing for inland water quality parameters prediction. *The Egyptian Journal of Remote Sensing and Space Science* 21(2), 193–200.
- Al-Kharusi, E. S., D. E. Tenenbaum, A. M. Abdi, T. Kutser, J. Karlsson, A. K. Bergström, e M. Berggren (2020). Large-scale retrieval of coloured dissolved organic matter in Northern Lakes using Sentinel-2 data. *Remote Sensing* 12(1), 157.
- Alcântara, E. H., J. L. Stech, J. A. Lorenzzetti, e E. M. L. M. Novo (2011). Time series analysis of water surface temperature and heat flux components in the Itumbiara Reservoir (GO), Brazil. *Acta Limnologica Brasiliensis* 23(3), 245–259.
- Almeida, D. F. (2010). Gestão ambiental dos sedimentos de corrente do Rio São Francisco na região de Três Marias/Minas Gerais. 2010. 105p. Tese (Doutorado em Engenharia Metalúrgica) – Universidade Federal de Minas Gerais, Belo Horizonte.
- Alparslan, E., H. G. Coskun, e U. Algancı (2009). Water quality determination of Küçükçekmece Lake, Turkey by using multispectral satellite data. *The Scientific World Journal* 9, 1215–1229.
- Alparslan, E., H. G. Coskun, e U. Algancı (2010). An investigation on water quality of Darlik Dam drinking water using satellite images. *The Scientific World Journal* 10, 1293–1306.
- Alsdorf, D. E. e D. P. Lettenmaier (2003). Tracking fresh water from space. *Science* 301(5639), 1491–1494.
- Alsdorf, D. E., J. M. Melack, T. Dunne, L. A. Mertes, L. L. Hess, e L. C. Smith (2000). Interferometric radar measurements of water level changes on the Amazon flood plain. *Nature* 404(6774), 174–177.
- ANA (2012). *Panorama da qualidade das águas superficiais do Brasil: 2012*, Volume 1. Superintendência de Planejamento de Recursos Hídricos.
- ANA (2015). ANA divulga publicação especial sobre a crise hídrica. <<https://www.ana.gov.br/noticias-antigas/ana-divulga-publicaassapo-especial-sobre-a-crise.2019-03-15.6633537236>>. ANA - Agência Nacional de Águas. Acesso em: 23 nov. 2020.

- Ansper, A. e K. Alikas (2019). Retrieval of chlorophyll a from Sentinel-2 MSI data for the european union water framework directive reporting purposes. *Remote Sensing* 11(1), 64.
- APHA (2012). *Standard methods for the examination of water and wastewater* (22 ed.). Washington: American Public Health Association.
- Araújo, S. C. S. (2015). Modelos de simulação baseados em raciocínio qualitativo para avaliação da qualidade da água em bacias hidrográficas. 2015. 287p. Tese (Doutorado em Ecologia) – Universidade de Brasília, Brasília.
- Avdan, Z. Y., G. Kaplan, S. Goncu, e U. Avdan (2019). Monitoring the water quality of small water bodies using high-resolution remote sensing data. *ISPRS International Journal of Geo-Information* 8(12), 553.
- AVISO (2020). A altimetria por satélite aplicada à hidrologia. <https://www.aviso.altimetry.fr/fileadmin/documents/kiosque/education/Alti-hydro-modellers_pt.pdf>. AVISO - Satellite Altimetry Data. Acesso em: 28 out. 2020.
- Babyak, M. (2004). What you see may not be what you get: a brief, nontechnical introduction to overfitting in regression-type models. *Psychosomatic medicine* 66(3), 411–421.
- Barbosa, C., R. Ferreira, C. Araujo, e E. Novo (2014). Bio-optical characterization of two Brazilian hydroelectric reservoirs as support to understand the carbon budget in hydroelectric reservoirs. In *IEEE Geoscience and Remote Sensing Symposium*, pp. 898–901. IEEE.
- Barbosa, C. C. F., E. M. L. M. Novo, e V. S. Martins (2019). *Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações*, Volume 1. Instituto Nacional de Pesquisas Espaciais.
- Barrett, D. C. e A. E. Frazier (2016). Automated method for monitoring water quality using Landsat imagery. *Water* 8(6), 257.
- Bassanezi, R. C. (2002). *Ensino-aprendizagem com modelagem matemática: uma nova estratégia*. São Paulo: Editora Contexto.
- Beck, M. (1983). Sensitivity analysis, calibration, and validation. In G. Orlob (Ed.), *Mathematical Modelling of Water Quality: Streams Lakes and Reservoirs*, Volume 12, Chapter 11, pp. 425–467. John Wiley & Sons.
- Benedetti, L. e F. Sforzi (1999). *Dynamic integrated modelling: a case study on the Lambro Catchment*. Universiteit Gent, Faculty of Agricultural and Applied Biological Sciences: Citeseer.
- Bertani, I., C. E. Steger, D. R. Obenour, G. L. Fahnenstiel, T. B. Bridgeman, T. H. Johengen, M. J. Sayers, R. A. Shuchman, e D. Scavia (2017). Tracking cyanobacteria blooms: Do different monitoring approaches tell the same story? *Science of the Total Environment* 575, 294–308.

- Binding, C., T. Greenberg, J. Jerome, R. Bukata, e G. Letourneau (2011). An assessment of MERIS algal products during an intense bloom in Lake of the Woods. *Journal of Plankton Research* 33(5), 793–806.
- Binding, C., T. Greenberg, G. McCullough, S. Watson, e E. Page (2018). An analysis of satellite-derived chlorophyll and algal bloom indices on Lake Winnipeg. *Journal of Great Lakes Research* 44(3), 436–446.
- Blanchon, D. (2009). *Atlas mondial de l'eau: de l'eau pour tous?* Paris: Éditions Autrement.
- Blix, K., K. Pálffy, V. R Tóth, e T. Eltoft (2018). Remote sensing of water quality parameters over Lake Balaton by using Sentinel-3 OLCI. *Water* 10(10), 1428.
- Bonansea, M., R. Bazán, C. Ledesma, C. Rodriguez, e L. Pinotti (2015). Monitoring of regional lake water clarity using Landsat imagery. *Hydrology Research* 46(5), 661–670.
- Bonansea, M., C. Rodriguez, e L. Pinotti (2018). Assessing the potential of integrating Landsat sensors for estimating chlorophyll-a concentration in a reservoir. *Hydrology Research* 49(5), 1608–1617.
- Braga, B., I. Hespanhol, J. G. L. Conejo, J. C. Mierzwa, M. T. L. Barros, M. Spencer, M. Porto, N. Nucci, N. Juliano, e S. Eiger (2005). *Introdução à Engenharia Ambiental*, Volume 2. São Paulo: Pearson Prentice Hall.
- BRANDT Meio Ambiente (2019). Relatório de Impacto Ambiental – UHE Três Marias. Technical report, BRANDT Meio Ambiente.
- Brasil (1997). Lei nº 9.433, de 08 de janeiro de 1997. Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos, regulamenta o inciso XIX do art. 21 da Constituição Federal, e altera o art. 1º da Lei nº 8.001, de 13 de março de 1990, que modificou a Lei nº 7.990, de 28 de dezembro de 1989. <http://www.planalto.gov.br/ccivil_03/LEIS/L9433.htm>. Brasília-DF. Acesso em: 25 mar. 2020.
- Brasil (2000). Lei nº 9.984, de 17 de julho de 2000. Dispõe sobre a criação da Agência Nacional de Águas - ANA, entidade federal de implementação da Política Nacional de Recursos Hídricos e de coordenação do Sistema Nacional de Gerenciamento de Recursos Hídricos, e dá outras providências. <http://www.planalto.gov.br/ccivil_03/LEIS/L9984.htm>. Brasília-DF. Acesso em: 25 mar. 2020.
- Brasil (2005). Resolução CONAMA nº 357, de 17 de março de 2005. Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes, e dá outras providências. <<http://www2.mma.gov.br/port/conama/legiabre.cfm?codlegi=459>>. Conselho Nacional do Meio Ambiente. Acesso em: 25 mar. 2020.

- Bresciani, M., R. Bolpagni, A. Laini, E. Matta, M. Bartoli, e C. Giardino (2013). Multitemporal analysis of algal blooms with MERIS images in a deep meromictic lake. *European Journal of Remote Sensing* 46(1), 445–458.
- Bresciani, M., I. Cazzaniga, M. Austoni, T. Sforzi, F. Buzzì, G. Morabito, e C. Giardino (2018). Mapping phytoplankton blooms in deep subalpine lakes from Sentinel-2A and Landsat-8. *Hydrobiologia* 824(1), 197–214.
- Bresciani, M., C. Giardino, R. Lauceri, E. Matta, I. Cazzaniga, M. Pinardi, A. Lami, M. Austoni, E. Viaggiu, R. Congestri, *et al.* (2017). Earth observation for monitoring and mapping of cyanobacteria blooms. Case studies on five Italian lakes. *Journal of Limnology* 76(1S), 127–139.
- Bresciani, M., M. Pinardi, G. Free, G. Luciani, S. Ghebrehiwot, M. Laanen, S. Peters, V. Della Bella, R. Padula, e C. Giardino (2020). The use of multisource optical sensors to study phytoplankton spatio-temporal variation in a shallow turbid lake. *Water* 12(1), 284.
- Bresciani, M., M. Vascellari, C. Giardino, e E. Matta (2012). Remote sensing supports the definition of the water quality status of Lake Omdeo (Italy). *European Journal of Remote Sensing* 45(1), 349–360.
- Brezonik, P., K. D. Menken, e M. Bauer (2005). Landsat-based remote sensing of lake water quality characteristics, including chlorophyll and colored dissolved organic matter (CDOM). *Lake and Reservoir Management* 21(4), 373–382.
- Cachapuz, P. B. B. (2006). *Usinas da CEMIG: a história da eletricidade em Minas e no Brasil, 1952–2005*. Rio de Janeiro: Centro da Memória da Eletricidade no Brasil, 2006.
- Campos, J. C. B. e E. P. F. Leite (2019). Procedimentos para análise e validação de atributos da qualidade da água. *Engenharia Sanitária e Ambiental* 24(3), 559–573.
- Canfield Jr, D. E., K. A. Langeland, M. J. Maceina, W. T. Haller, J. V. Shireman, e J. R. Jones (1983). Trophic state classification of lakes with aquatic macrophytes. *Canadian Journal of Fisheries and Aquatic Sciences* 40(10), 1713–1718.
- Cao, Z., R. Ma, H. Duan, K. Xue, e M. Shen (2019). Effect of satellite temporal resolution on long-term suspended particulate matter in inland lakes. *Remote Sensing* 11(23), 2785.
- Carpenter, S. R., E. H. Stanley, e M. J. V. Zandbergen (2011). State of the world's freshwater ecosystems: physical, chemical, and biological changes. *Annual review of Environment and Resources* 36, 75–99.
- Castilho, A. S. (1996). Rede hidrometeorológica e caracterização física da bacia do Alto São Francisco. Technical report, CPRM - Serviço Geológico do Brasil.
- CEMIG (2009). *Manual de Procedimentos de Coleta e Metodologias de Análise de Água*, Volume 1. Companhia Energética de Minas Gerais.

- Chapra, S. C. (1997). *Surface water-quality modeling*. Illinois: Waveland press.
- Chelotti, G. B., J. M. Martinez, H. L. Roig, e D. Olivetti (2019). Space-temporal analysis of suspended sediment in low concentration reservoir by remote sensing. *RBRH* 24.
- Chen, F., G. Wu, J. Wang, J. He, e Y. Wang (2016). A MODIS-based retrieval model of suspended particulate matter concentration for the two largest freshwater lakes in China. *Sustainability* 8(8), 832.
- Chen, J., W.-N. Zhu, Y. Q. Tian, e Q. Yu (2017). Estimation of colored dissolved organic matter from Landsat-8 imagery for complex inland water: case study of Lake Huron. *IEEE Transactions on Geoscience and Remote Sensing* 55(4), 2201–2212.
- Cheng, C., Y. Wei, G. Lv, e Z. Yuan (2013). Remote estimation of chlorophyll-a concentration in turbid water using a spectral index: a case study in Taihu Lake, China. *Journal of Applied Remote Sensing* 7(1), 073465.
- Christofoletti, A. (1999). *Modelagem de sistemas ambientais*. São Paulo: Edgard Blücher.
- Coelho, C., B. Heim, S. Foerster, A. Brosinsky, e J. C. Araújo (2017). In situ and satellite observation of CDOM and chlorophyll-a dynamics in small water surface reservoirs in the Brazilian semiarid region. *Water* 9(12), 913.
- Coelho, R. M. P. (2006). Estudo técnico científico visando a delimitação de parques aquícolas nos lagos das usinas hidroelétricas de Furnas e Três Marias. Technical report, SECTES - Secretaria de Estado de Ciência, Tecnologia e Ensino Superior de Minas Gerais.
- Costa, C. M. S. B., L. S. Marques, A. K. Almeida, I. R. Leite, e I. K. Almeida (2019). Applicability of water quality models around the world - a review. *Environmental Science and Pollution Research International* 26(36), 36141–36162.
- Cox, B. A. (2003). A review of currently available in-stream water-quality models and their applicability for simulating dissolved oxygen in lowland rivers. *Science of the total environment* 314, 335–377.
- Cox Jr, R. M., R. D. Forsythe, G. E. Vaughan, e L. L. Olmsted (1998). Assessing water quality in Catawba River Reservoirs using Landsat Thematic Mapper satellite data. *Lake and Reservoir Management* 14(4), 405–416.
- Creteaux, J. F., M. Berge-Nguyen, S. Calmant, N. Jamangulova, R. Satylkanov, F. Lyard, F. Perosanz, J. Verron, A. Samine Montazem, G. Le Guilcher, D. Leroux, J. Barrie, P. Maisongrande, e P. Bonnefond (2018). Absolute calibration or validation of the altimeters on the Sentinel-3A and the Jason-3 over Lake Issyk-Kul (Kyrgyzstan). *Remote Sensing* 10(11), 1679.

- Cui, L., Y. Qiu, T. Fei, Y. Liu, e G. Wu (2013). Using remotely sensed suspended sediment concentration variation to improve management of Poyang Lake, China. *Lake and Reservoir Management* 29(1), 47–60.
- Curtarelli, V. P. (2020). Parametrização de algoritmos semi-analíticos para estimativa do coeficiente de atenuação difusa espectral (Kd) do Reservatório de Três Marias por sensoriamento remoto. 2020. 139p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- Dörnhöfer, K., A. Göritz, P. Gege, B. Pflug, e N. Oppelt (2016). Water constituents and water depth retrieval from Sentinel-2A — a first evaluation in an oligotrophic lake. *Remote Sensing* 8(11), 941.
- Elhag, M., I. Gitas, A. Othman, J. Bahrawi, e P. Gikas (2019). Assessment of water quality parameters using temporal remote sensing spectral reflectance in arid environments, Saudi Arabia. *Water* 11(3), 556.
- ESA (2021). Sentinel-2 MSI User Guide. <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>>. ESA - European Space Agency. Acesso em: 07 dez. 2021.
- Esteves, F. A. (1998). *Fundamentos de limnologia*. Rio de Janeiro: Interciênciam.
- Eugenio, F., J. Marcello, e J. Martín (2020). Multiplatform earth observation systems for monitoring water quality in vulnerable inland ecosystems: Maspalomas Water Lagoon. *Remote Sensing* 12(2), 284.
- Ferreira, A., F. Pizani, P. Maillard, e C. Amorim (2020). Utilização do mapa de uso e ocupação do solo do entorno do Reservatório de Três Marias como ferramenta de tomada de decisão para a definição dos pontos de monitoramento da qualidade da água. In *III Simpósio da Bacia Hidrográfica do Rio São Francisco*, pp. 1–8. Even3.
- Ferreira, M. S. e M. L. B. Galo (2013). Chlorophyll a spatial inference using artificial neural network from multispectral images and in situ measurements. *Anais da Academia Brasileira de Ciências* 85(2), 519–532.
- Ferreira, R. M. P. (2014). Caracterização da ótica e do carbono orgânico dissolvido no Reservatório de Três Marias/MG. 2014. 128p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- Fleck, L., M. H. F. Tavares, e E. Eyng (2013). Especificidades e importância de modelos matemáticos de qualidade da água. *Revista Eixo* 2(1), 106–119.
- Flores-Anderson, A. I., R. Griffin, M. Dix, C. S. Romero-Oliva, G. Ochaeta, J. Skinner-Alvarado, M. V. Ramirez Moran, B. Hernandez, E. Cherrington, B. Page, *et al.* (2020). Hyperspectral satellite remote sensing of water quality in Lake Atitlán, Guatemala. *Frontiers in Environmental Science* 8, 7.

- Gholizadeh, M. H., A. M. Melesse, e L. Reddi (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors* 16(8), 1298.
- Giardino, C., M. Bresciani, I. Cazzaniga, K. Schenk, P. Rieger, F. Braga, E. Matta, e V. E. Brando (2014). Evaluation of multi-resolution satellite sensors for assessing water quality and bottom depth of Lake Garda. *Sensors* 14(12), 24116–24131.
- Giardino, C., M. Bresciani, R. Pilkaityte, M. Bartoli, e A. Razinkovas (2010). In situ measurements and satellite remote sensing of case 2 waters: first results from the Curonian Lagoon. *Oceanologia* 52(2), 197–210.
- Giardino, C., M. Bresciani, P. Villa, e A. Martinelli (2010). Application of remote sensing in water resource management: the case study of Lake Trasimeno, Italy. *Water resources management* 24(14), 3885–3899.
- Guimarães, D. P., R. J. Reis, e E. C. Landau (2010). Índices pluviométricos em Minas Gerais. Technical report, Embrapa Milho e Sorgo-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E).
- Guimarães, T. T., M. R. Veronez, E. C. Koste, E. M. Souza, D. Brum, L. Gonzaga, e F. F. Mauad (2019). Evaluation of regression analysis and neural networks to predict total suspended solids in water bodies from Unmanned Aerial Vehicle images. *Sustainability* 11(9), 2580.
- Ha, N. T. T., N. T. P. Thao, K. Koike, e M. T. Nhuan (2017). Selecting the best band ratio to estimate chlorophyll-a concentration in a tropical freshwater lake using Sentinel 2A images from a case study of Lake Ba Be (Northern Vietnam). *ISPRS International Journal of Geo-Information* 6(9), 290.
- Hadjimitsis, D. G. e C. Clayton (2011). Field spectroscopy for assisting water quality monitoring and assessment in water treatment reservoirs using atmospheric corrected satellite remotely sensed imagery. *Remote Sensing* 3(2), 362–377.
- Hair, J. F., R. E. Anderson, R. L. Tatham, e W. C. Black (2005). *Análise multivariada de dados*, Volume 1. Bookman.
- Hansen, C. H. e G. P. Williams (2018). Evaluating remote sensing model specification methods for estimating water quality in optically diverse lakes throughout the growing season. *Hydrology* 5(4), 62.
- Harvey, T. (2015). Bio-optics, satellite remote sensing and baltic sea ecosystems: applications for monitoring and management. 2015. 58p. Tese (Doutorado em Ecologia Marinha) – Stockholm University, Stockholm.
- Huo, A., J. Zhang, C. Qiao, C. Li, J. Xie, J. Wang, e X. Zhang (2014). Multispectral remote sensing inversion for city landscape water eutrophication based on Genetic Algorithm-Support Vector Machine. *Water Quality Research Journal of Canada* 49(3), 285–293.

- IGAM (2015). Relatório hidrometeorológico – Período chuvoso 2014/2015. Technical report, SEMAD - Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável.
- IGAM (2019). Avaliação da qualidade das águas superficiais de Minas Gerais em 2018: Resumo Executivo Anual. Technical report, IGAM - Instituto Mineiro de Gestão das Águas.
- IGAM (2020). Enquadramento. <<http://www.igam.mg.gov.br/gestao-das-aguas/enquadramento>>. Instituto Mineiro de Gestão das Águas. Acesso em: 26 mar. 2020.
- Jensen, J. R. (2009). *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. São José dos Campos: Parêntese.
- Jesus, J. A. O. (2006). Utilização de modelagem matemática 3D na gestão da qualidade da água em mananciais - aplicação no Reservatório Billings. 2006. 156p. Tese (Doutorado em Saúde Pública) – Universidade de São Paulo, São Paulo.
- Jiang, G., D. Liu, K. Song, Z. Wang, B. Zhang, e Y. Wang (2010). Application of multivariate model based on three simulated sensors for water quality variables estimation in Shitoukoumen Reservoir, Jilin province, China. *Chinese Geographical Science* 20(4), 337–344.
- Kallio, K., J. Attila, P. Härmä, S. Koponen, J. Pulliainen, U.-M. Hyytiäinen, e T. Pyhälähti (2008). Landsat ETM+ images in the estimation of seasonal lake water quality in boreal river basins. *Environmental Management* 42(3), 511–522.
- Kapalanga, T. S., Z. Hoko, W. Gumindoga, e L. Chikwiramakomo (2021). Remote-sensing-based algorithms for water quality monitoring in Olushandja Dam, north-central Namibia. *Water Supply* 21(5), 1878–1894.
- Karaoui, I., A. Arioua, A. Boudhar, M. Hssaisoune, S. El Mouatassime, K. Ouhamchich, D. Elhamdouni, A. Idrissi, e W. Nouaim (2019). Evaluating the potential of Sentinel-2 satellite images for water quality characterization of artificial reservoirs: The Bin El Ouidane reservoir case study (Morocco). *Meteorology Hydrology and Water Management. Research and Operational Applications* 7(1), 31–39.
- Kimmel, B. L. e A. W. Groeger (1984). Factors controlling primary production in lakes and reservoirs: a perspective. *Lake and reservoir management* 1(1), 277–281.
- Knight, J. F. e M. L. Voth (2012). Application of MODIS imagery for intra-annual water clarity assessment of Minnesota lakes. *Remote Sensing* 4(7), 2181–2198.
- Koponen, S. (2006). Remote sensing of water quality for Finnish lakes and coastal areas. 2006. 85p. Tese (Doutorado em Tecnologia) – Helsinki University of Technology, Helsinki.
- Kupssinskü, L. S., T. T. Guimarães, E. M. Souza, D. C. Zanotta, M. R. Veronez, L. Gonzaga, e F. F. Mauad (2020). A method for chlorophyll-a and suspended solids prediction through remote sensing and machine learning. *Sensors* 20(7), 2125.

- Kutser, T., B. Paavel, C. Verpoorter, M. Ligi, T. Soomets, K. Toming, e G. Casal (2016). Remote sensing of black lakes and using 810 nm reflectance peak for retrieving water quality parameters of optically complex waters. *Remote Sensing* 8(6), 497.
- Kutser, T., D. C. Pierson, K. Y. Kallio, A. Reinart, e S. Sobek (2005). Mapping lake CDOM by satellite remote sensing. *Remote Sensing of Environment* 94(4), 535–540.
- Lacaux, J., Y. Tourre, C. Vignolles, J. Ndione, e M. Lafaye (2007). Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley fever epidemics in Senegal. *Remote Sensing of Environment* 106(1), 66–74.
- Lehmann, M. K., U. Nguyen, M. Allan, e H. J. Van der Woerd (2018). Colour classification of 1486 lakes across a wide range of optical water types. *Remote Sensing* 10(8), 1273.
- Li, X., M. Huang, e R. Wang (2020). Numerical simulation of Donghu Lake hydrodynamics and water quality based on remote sensing and MIKE 21. *ISPRS International Journal of Geo-Information* 9(2), 94.
- Li, Y., K. Shi, Y. Zhang, G. Zhu, Y. Zhang, Z. Wu, M. Liu, Y. Guo, e N. Li (2020). Analysis of water clarity decrease in Xin'anjiang Reservoir, China, from 30-year Landsat TM, ETM+, and OLI observations. *Journal of Hydrology* 590, 125476.
- Li, Y., L. Tian, W. Li, J. Li, A. Wei, S. Li, e R. Tong (2020). Design and experiments of a water color remote sensing-oriented unmanned surface vehicle. *Sensors* 20(8), 2183.
- Li, Y., Q. Zhang, L. Zhang, Z. Tan, e J. Yao (2017). Investigation of water temperature variations and sensitivities in a large floodplain lake system (Poyang Lake, China) using a hydrodynamic model. *Remote Sensing* 9(12), 1231.
- Li, Y., Y. Zhang, K. Shi, G. Zhu, Y. Zhou, Y. Zhang, e Y. Guo (2017). Monitoring spatiotemporal variations in nutrients in a large drinking water reservoir and their relationships with hydrological and meteorological conditions based on Landsat 8 imagery. *Science of the Total Environment* 599, 1705–1717.
- Liu, J., Y. Zhang, D. Yuan, e X. Song (2015). Empirical estimation of total nitrogen and total phosphorus concentration of urban water bodies in China using high resolution IKONOS multispectral imagery. *Water* 7(11), 6551–6573.
- Liu, L. e Y. Wang (2019). Modelling reservoir turbidity using Landsat-8 satellite imagery by gene expression programming. *Water* 11(7), 1479.
- Liu, X., Z. Lee, Y. Zhang, J. Lin, K. Shi, Y. Zhou, B. Qin, e Z. Sun (2019). Remote sensing of Secchi depth in highly turbid lake waters and its application with MERIS data. *Remote Sensing* 11(19), 2226.

- Liu, Y., M. A. Islam, e J. Gao (2003). Quantification of shallow water quality parameters by means of remote sensing. *Progress in Physical Geography* 27(1), 24–43.
- Lonjou, V., C. Desjardins, O. Hagolle, B. Petrucci, T. Tremas, M. Dejus, A. Makarau, e S. Auer (2016). MACCS-ATCOR joint algorithm (MAJA). In *Remote Sensing of Clouds and the Atmosphere XXI*, Volume 10001, pp. 1–13. International Society for Optics and Photonics.
- Machado, M. T. S. e G. M. M. Baptista (2016). Sensoriamento remoto como ferramenta de monitoramento da qualidade da água do Lago Paranoá (DF). *Engenharia Sanitária e Ambiental* 21(2), 357–365.
- Mainali, J., H. Chang, e Y. Chun (2019). A review of spatial statistical approaches to modeling water quality. *Progress in Physical Geography: Earth and Environment* 43(6), 841–826.
- Malahlela, O. E., T. Oliphant, L. T. Tsoeleng, e P. Mhangara (2018). Mapping chlorophyll-a concentrations in a cyanobacteria- and algae-impacted Vaal Dam using Landsat 8 OLI data. *South African Journal of Science* 114(9-10), 1–9.
- Mancino, G., A. Nolè, V. Urbano, M. Amato, e A. Ferrara (2009). Assessing water quality by remote sensing in small lakes: the case study of Monticchio lakes in southern Italy. *iForest-Biogeosciences and Forestry* 2(4), 154.
- Markelin, L., S. G. Simis, P. D. Hunter, E. Spyarakos, A. N. Tyler, D. Clewley, e S. Groom (2017). Atmospheric correction performance of hyperspectral airborne imagery over a small eutrophic lake under changing cloud cover. *Remote Sensing* 9(1), 2.
- Markert, K. N., C. M. Schmidt, R. E. Griffin, A. I. Flores, A. Poortinga, D. S. Saah, R. E. Muench, N. E. Clinton, F. Chishtie, K. Kityuttachai, *et al.* (2018). Historical and operational monitoring of surface sediments in the lower Mekong Basin using Landsat and Google Earth Engine cloud computing. *Remote Sensing* 10(6), 909.
- Markogianni, V., D. Kalivas, G. P. Petropoulos, e E. Dimitriou (2018). An appraisal of the potential of Landsat 8 in estimating chlorophyll-a, ammonium concentrations and other water quality indicators. *Remote Sensing* 10(7), 1018.
- Mas, J. F. e J. J. Flores (2008). The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing* 29(3), 617–663.
- Matthews, M. (2011). A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. *International Journal of Remote Sensing* 32(21), 6855–6899.
- Matthews, M. W. e S. Bernard (2015). Eutrophication and cyanobacteria in South Africa's standing water bodies: A view from space. *South African journal of science* 111(5-6), 1–8.
- McCoy, R. M. (2005). *Field methods in remote sensing*. New York: Guilford Press.

- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17(7), 1425–1432.
- Menken, K. D., P. L. Brezonik, e M. E. Bauer (2006). Influence of chlorophyll and colored dissolved organic matter (CDOM) on lake reflectance spectra: Implications for measuring lake properties by remote sensing. *Lake and Reservoir Management* 22(3), 179–190.
- Mertes, L. A., A. Dekker, G. Brakenridge, C. Birkett, e G. Letournou (2004). Rivers and lakes. In S. L. Ustin (Ed.), *Manual of Remote Sensing: Remote Sensing for Natural Resource Management and Environmental Monitoring*, Chapter 7, pp. 345–400. New York: John Wiley & Sons.
- Minas Gerais (2008). Deliberação Normativa Conjunta COPAM/CERH-MG nº 01, de 05 de maio de 2008. Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes, e dá outras providências. <<http://www.siam.mg.gov.br/sla/download.pdf?idNorma=8151>>. Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável. Acesso em: 26 mar. 2020.
- Mishra, D. R., I. Ogashawara, e A. A. Gitelson (2017). *Bio-optical modeling and remote sensing of inland waters*, Volume 1. Elsevier Science.
- Mishra, S. e D. Mishra (2014). A novel remote sensing algorithm to quantify phycocyanin in cyanobacterial algal blooms. *Environmental Research Letters* 9(11), 114003.
- Mollaee, S. (2018). Estimation of phytoplankton chlorophyll-a concentration in the western basin of Lake Erie using Sentinel-2 and Sentinel-3 data. 2018. 93p. Dissertação (Mestrado em Geografia) – University of Waterloo, Ontario.
- Moore, D. (1998). Ambient water quality criteria for organic carbon in British Columbia. Technical report, British Columbia Ministry of Environment & Climate Change Strategy.
- Mouchot, M. C., M. Grenier, e G. Létourneau (1996). Télédétection de la qualité de l'eau. In F. Bonn (Ed.), *Précis de télédétection: Volume 2 – Applications thématiques*, Chapter 11, pp. 393–426. Québec: Presses de l'université du Québec.
- Moura Júnior, E. G., M. C. Abreu, W. Severi, e G. A. S. T. Lira (2011). O gradiente rio-barragem do Reservatório de Sobradinho afeta a composição florística, riqueza e formas biológicas das macrófitas aquáticas? *Rodriguésia* 62(4), 731–742.
- Mulligan, A. E. e L. C. Brown (1998). Genetic algorithms for calibrating water quality models. *Journal of environmental engineering* 124(3), 202–211.
- Naessens, W., T. Maere, e I. Nopens (2012). Critical review of membrane bioreactor models—part 1: Biokinetic and filtration models. *Bioresource technology* 122, 95–106.

- Niroumand-Jadidi, M., F. Bovolo, e L. Bruzzone (2019). Novel spectra-derived features for empirical retrieval of water quality parameters: Demonstrations for OLI, MSI, and OLCI sensors. *IEEE Transactions on Geoscience and Remote Sensing* 57(12), 10285–10300.
- Novo, E., C. Barbosa, e F. Lobo (2009). Comportamento espectral dos ambientes aquáticos. In P. Meneses, T. Almeida, e G. Baptista (Eds.), *Reflectância dos materiais terrestres: análise e interpretação*, Chapter 7, pp. 225–245. São Paulo: Oficina de Textos.
- Novo, E. M. L. M., L. R. Londe, C. Barbosa, C. A. Araujo, e C. D. Rennó (2013). Proposal for a remote sensing trophic state index based upon Thematic Mapper/Landsat images. *Revista Ambiente & Água* 8(3), 65–82.
- Novotny, V. (2002). *Water quality: diffuse pollution and watershed management*. New York: John Wiley & Sons.
- Odermatt, D., O. Danne, P. Philipson, e C. Brockmann (2018). Diversity II water quality parameters from ENVISAT (2002-2012): a new global information source for lakes. *Earth System Science Data* 10(3).
- Odermatt, D., T. Heege, J. Nieke, M. Kneubühler, e K. Itten (2008). Water quality monitoring for Lake Constance with a physically based algorithm for MERIS data. *Sensors* 8(8), 4582–4599.
- Ogashawara, I. (2019). The use of Sentinel-3 imagery to monitor cyanobacterial blooms. *Environments* 6(6), 60.
- Ogashawara, I., E. H. Alcântara, M. P. Curtarelli, M. Adami, R. F. Nascimento, A. F. Souza, J. L. Stech, e M. Kampel (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 Sensing* 6(2), 1634–1653.
- Ogashawara, I., E. H. Alcântara, J. L. Stech, e J. G. Tundisi (2014). Cyanobacteria detection in Guarapiranga Reservoir (São Paulo state, Brazil) using Landsat TM and ETM+ images. *Revista Ambiente & Água* 9(2), 224–238.
- Ogashawara, I., M. P. Curtarelli, C. A. Araujo, e J. L. Stech (2016). Bio-optical modeling in a tropical hypersaline lagoon environment. *Environmental Applications of Remote Sensing* 1, 235.
- Ogashawara, I. e M. J. Moreno-Madriñán (2014). Improving inland water quality monitoring through remote sensing techniques. *ISPRS International Journal of Geo-Information* 3(4), 1234–1255.
- Oliveira, A. R. M. (2017). Desenvolvimento de índices de qualidade da água com número reduzido de parâmetros. 2017. 129p. Tese (Doutorado em Engenharia Agrícola) – Universidade de Viçosa, Viçosa.

- Pahlevan, N., B. Smith, J. Schalles, C. Binding, Z. Cao, R. Ma, K. Alikas, K. Kangro, D. Gurlin, N. Hà, et al. (2020). Seamless retrievals of chlorophyll-a from Sentinel-2 (MSI) and Sentinel-3 (OLCI) in inland and coastal waters: A machine-learning approach. *Remote Sensing of Environment*, 111604.
- Palmer, S. C., D. Odermatt, P. Hunter, C. Brockmann, M. Presing, H. Balzter, e V. Tóth (2015). Satellite remote sensing of phytoplankton phenology in Lake Balaton using 10 years of MERIS observations. *Remote Sensing of Environment* 158, 441–452.
- Pedra, F. T. C. (2014). Análise da cobertura vegetal nas áreas de APP da bacia do reservatório Várzea das Flores-MG. 2014. 36p. Monografia (Especialização em Geoprocessamento) – Universidade Federal de Minas Gerais, Belo Horizonte.
- Peppa, M., C. Vasilakos, e D. Kavroudakis (2020). Eutrophication monitoring for Lake Pamvotis, Greece, using Sentinel-2 data. *ISPRS International Journal of Geo-Information* 9(3), 143.
- Pereira, G. H. A., M. Lohmann, e R. F. Maganhotto (2016). Proposta e avaliação de índices para delimitar e mapear corpos d'água utilizando imagens do satélite Landsat-8. *Revista Brasileira de Geografia Física* 9(06), 1956–1968.
- Pereira, L. H. (2016). Análise de sensibilidade e propagação de incerteza em modelos hidrossedimentológicos: contribuição à modelagem de bacias hidrográficas. 2016. 101p. Tese (Doutorado em Geografia) – Universidade Estadual Paulista, Rio Claro.
- Philipson, P., S. Kratzer, S. Ben Mustapha, N. Strömbeck, e K. Stelzer (2016). Satellite-based water quality monitoring in Lake Vänern, Sweden. *International Journal of Remote Sensing* 37(16), 3938–3960.
- Pinardi, M., A. Fenocchi, C. Giardino, S. Sibilla, M. Bartoli, e M. Bresciani (2015). Assessing potential algal blooms in a shallow fluvial lake by combining hydrodynamic modelling and remote-sensed images. *Water* 7(5), 1921–1942.
- Pinto, C. E., P. H. Menezes, J. M. Martinez, H. L. Roig, e R. A. Villar (2014). Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias. *Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi* 18(5), 507–516.
- Politi, E., M. E. Cutler, e J. S. Rowan (2015). Evaluating the spatial transferability and temporal repeatability of remote-sensing-based lake water quality retrieval algorithms at the European scale: a meta-analysis approach. *International Journal of Remote Sensing* 36(11), 2995–3023.
- Potes, M., M. J. Costa, e R. Salgado (2012). Satellite remote sensing of water turbidity in Alqueva Reservoir and implications on lake modelling. *Hydrology & Earth System Sciences* 16(6).
- Pu, F., C. Ding, Z. Chao, Y. Yu, e X. Xu (2019). Water-quality classification of inland lakes using Landsat8 images by convolutional neural networks. *Remote Sensing* 11(14), 1674.

- Pyo, J. C., M. Ligaray, Y. S. Kwon, M. H. Ahn, K. Kim, H. Lee, T. Kang, S. B. Cho, Y. Park, e K. H. Cho (2018). High-spatial resolution monitoring of phycocyanin and chlorophyll-a using airborne hyperspectral imagery. *Remote Sensing* 10(8), 1180.
- Quang, N. H., J. Sasaki, H. Higa, e N. H. Huan (2017). Spatiotemporal variation of turbidity based on Landsat 8 OLI in Cam Ranh Bay and Thuy Trieu Lagoon, Vietnam. *Water* 9(8), 570.
- Robert, E., L. Kerfoot, N. Soumaguel, S. Merlet, J. M. Martinez, M. Diawara, e M. Grippa (2017). Analysis of suspended particulate matter and its drivers in Sahelian ponds and lakes by remote sensing (Landsat and MODIS): Gourma region, Mali. *Remote Sensing* 9(12), 1272.
- Rode, M., U. Suhr, e G. Wriedt (2007). Multi-objective calibration of a river water quality model - information content of calibration data. *Ecological Modelling* 204(1-2), 129–142.
- Rodrigues, T., E. Alcântara, F. Watanabe, e N. Imai (2017). Retrieval of Secchi disk depth from a reservoir using a semi-analytical scheme. *Remote Sensing of Environment* 198, 213–228.
- Rosmorduc, V., J. Benveniste, O. Lauret, M. Milagro, e N. Picot (2006). *Radar Altimetry Tutorial*. <http://www.altimetry.info>.
- Ruescas, A. B., M. Hieronymi, G. Mateo-Garcia, S. Koponen, K. Kallio, e G. Camps-Valls (2018). Machine learning regression approaches for colored dissolved organic matter (CDOM) retrieval with S2-MSI and S3-OLCI simulated data. *Remote Sensing* 10(5), 786.
- Sabat-Tomala, A., A. M. Jarocińska, B. Zagajewski, A. S. Magnuszewski, Ł. M. Sławik, A. Ochtyra, E. Raczkó, e J. R. Lechnio (2018). Application of HySpex hyperspectral images for verification of a two-dimensional hydrodynamic model. *European Journal of Remote Sensing* 51(1), 637–649.
- Salama, M., A. Dekker, Z. Su, C. Mannaerts, e W. Verhoef (2009). Deriving inherent optical properties and associated inversion-uncertainties in the Dutch Lakes. *Hydrology and Earth System Sciences* 13(7), 1113.
- Sambur, M. (1975). Selection of acoustic features for speaker identification. *IEEE Transactions on Acoustics, Speech, and Signal Processing* 23(2), 176–182.
- Santos, I., H. D. Fill, M. R. V. B. Sugai, H. Buba, R. T. Kishi, E. Marone, e L. F. Lautert (2001). *Hidrometria aplicada*, Volume 1. Curitiba: Instituto de Tecnologia para o Desenvolvimento.
- Shapiro, R. (2004). Nimbus program history: Earth-resources research satellite program. *USA: NASA goddard space flight center* 1, 1–34.
- Silva, A. P. S., H. C. T. Dias, R. K. X. Bastos, e E. Silva (2009). Qualidade da água do reservatório da Usina Hidrelétrica (UHE) de Peti, Minas Gerais. *Revista Árvore* 33(6), 1063–1069.
- Silva, H. A. N., P. G. V. Naranjo, L. P. S. Rodrigues, D. M. Araújo, e Y. P. Pires (2020). Prediction of some physico-chemical parameters of water in Alton Reservoir, Suffolk, England. *WSEAS Transactions on Environment and Development* 16, 119–131.

- Silva, M. M. A. P. M., S. D. Faria, e P. M. Moura (2017). Modelagem da qualidade da água na bacia hidrográfica do Rio Piracicaba (MG). *Engenharia Sanitária e Ambiental* 22(1), 133–143.
- Son, S. e M. Wang (2019). VIIRS-Derived water turbidity in the Great Lakes. *Remote Sensing* 11(12), 1448.
- Soomets, T., K. Uudeberg, D. Jakovels, A. Brauns, M. Zagars, e T. Kutser (2020). Validation and comparison of water quality products in baltic lakes using Sentinel-2 MSI and Sentinel-3 OLCI data. *Sensors* 20(3), 742.
- Sòria-Perpinyà, X., E. Vicente, P. Urrego, M. Pereira-Sandoval, A. Ruíz-Verdú, J. Delegido, J. M. Soria, e J. Moreno (2020). Remote sensing of cyanobacterial blooms in a hypertrophic lagoon (Albufera of València, Eastern Iberian Peninsula) using multitemporal Sentinel-2 images. *Science of The Total Environment* 698, 134305.
- Stefouli, M. e E. Charou (2012). Monitoring of transnational lakes using geomatic techniques: a case study for Prespa lakes. *International Journal of Design & Nature and Ecodynamics* 7(2), 199–209.
- Teodoro, A. C. (2016). Optical satellite remote sensing of the coastal zone environment - an overview. *Environment Applications of Remote Sensing. London, UK, InTechOpen* 1, 165–196.
- Tomig, K., T. Kutser, A. Laas, M. Sepp, B. Paavel, e T. Nõges (2016). First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. *Remote Sensing* 8(8), 640.
- Topp, S. N., T. M. Pavelsky, D. Jensen, M. Simard, e M. R. Ross (2020). Research trends in the use of remote sensing for inland water quality science: Moving towards multidisciplinary applications. *Water* 12(1), 169.
- Torbick, N. e M. Corbiere (2015). A multiscale mapping assessment of Lake Champlain cyanobacterial harmful algal blooms. *International journal of environmental research and public health* 12(9), 11560–11578.
- Torbick, N., S. Hession, E. Stommel, e T. Caller (2014). Mapping amyotrophic lateral sclerosis lake risk factors across northern New England. *International journal of health geographics* 13(1), 1.
- Torbick, N., B. Ziniti, E. Stommel, E. Linder, A. Andrew, T. Caller, J. Haney, W. Bradley, P. L. Henegan, e X. Shi (2018). Assessing cyanobacterial harmful algal blooms as risk factors for amyotrophic lateral sclerosis. *Neurotoxicity research* 33(1), 199–212.
- Torres-Bejarano, F., F. Arteaga-Hernández, D. Rodríguez-Ibarra, D. Mejía-Ávila, e L. González-Márquez (2021). Water quality assessment in a wetland complex using Sentinel 2 satellite images. *International Journal of Environmental Science and Technology* 18(8), 2345–2356.
- Tu, M., P. Smith, e A. M. Filippi (2018). Hybrid forward-selection method-based water-quality estimation via combining Landsat TM, ETM+, and OLI/TIRS images and ancillary environmental data. *PloS one* 13(7).

- Tucci, C. E. (1998). *Modelos hidrológicos*. Porto Alegre: Editora UFRGS/ABRH.
- Uudeberg, K., A. Aavaste, K. Kōks, A. Ansper, M. Uusōue, K. Kangro, I. Ansko, M. Ligi, K. Toming, e A. Reinart (2020). Optical water type guided approach to estimate optical water quality parameters. *Remote Sensing* 12(6), 931.
- Van der Merwe, D. e K. P. Price (2015). Harmful algal bloom characterization at ultra-high spatial and temporal resolution using small unmanned aircraft systems. *Toxins* 7(4), 1065–1078.
- Van Nguyen, M., C. H. Lin, H. J. Chu, L. M. Jaelani, e M. A. Syariz (2020). Spectral feature selection optimization for water quality estimation. *International Journal of Environmental Research and Public Health* 17(1), 272.
- Veronez, M. R., L. S. Kupssinskü, T. T. Guimarães, E. C. Koste, J. M. Silva, L. V. Souza, W. F. Oliverio, R. S. Jardim, I. É. Koch, J. G. Souza, L. Gonzaga Junior, F. F. Mauad, L. C. Inocencio, e F. Bordin (2018). Proposal of a method to determine the correlation between total suspended solids and dissolved organic matter in water bodies from spectral imaging and artificial neural networks. *Sensors* 18(1), 159.
- Verschuur, G. L. (1997). Transparency measurements in Garner Lake, Tennessee: the relationship between Secchi depth and solar altitude and a suggestion for normalization of Secchi depth data. *Lake and Reservoir Management* 13(2), 142–153.
- Vilela, M. A. M. A. (2010). Metodologia para monitoramento da qualidade da água de reservatórios utilizando sensoriamento remoto. 2010. 123p. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Uberlândia, Uberlândia.
- Von Sperling, E. (1999). *Morfologia de lagos e represas*. Belo Horizonte: DESA/UFMG.
- Von Sperling, M. (2007a). *Estudos e modelagem da qualidade da água de rios*. Belo Horizonte: DESA/UFMG.
- Von Sperling, M. (2007b). *Introdução à qualidade das águas e ao tratamento de esgotos*. Belo Horizonte: DESA/UFMG.
- Vundo, A., B. Matsushita, D. Jiang, M. Gondwe, R. Hamzah, F. Setiawan, e T. Fukushima (2019). An overall evaluation of water transparency in Lake Malawi from MERIS data. *Remote Sensing* 11(3), 279.
- Wang, D., Y. Kageyama, M. Nishida, e H. Shirai (2012). Algorithm to analyze water quality conditions of Lake Hachiroko using textures of JERS-1 SAR data. *International Journal of the Society of Materials Engineering for Resources* 18(2), 51–58.
- Wang, D., Y. Kageyama, M. Nishida, H. Shirai, e C. Kasai (2014). Water quality analysis of Lake Hachiroko, Japan, using ALOS PALSAR data. *International Journal of the Society of Materials Engineering for Resources* 20(2), 175–180.

- Wang, Q., S. Li, P. Jia, C. Qi, e F. Ding (2013). A review of surface water quality models. *The Scientific World Journal* 2013, 1–7.
- Wang, X., K. Song, Z. Wen, G. Liu, Y. Shang, C. Fang, L. Lyu, e Q. Wang (2021). Quantifying turbidity variation for lakes in Daqing of Northeast China using landsat images from 1984 to 2018. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 14, 8884–8897.
- Warren, M. A., S. G. Simis, V. Martinez-Vicente, K. Poser, M. Bresciani, K. Alikas, E. Spyarakos, C. Giardino, e A. Ansper (2019). Assessment of atmospheric correction algorithms for the Sentinel-2A MultiSpectral Imager over coastal and inland waters. *Remote Sensing of Environment* 225, 267–289.
- Watanabe, F., E. Alcantara, T. Rodrigues, L. Rotta, N. Bernardo, e N. Imai (2018). Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita Reservoir, Brazil). *Anais da Academia Brasileira de Ciências* 90(2), 1987–2000.
- Watanabe, F. S. Y., E. Alcântara, T. W. P. Rodrigues, N. N. Imai, C. C. F. Barbosa, e L. H. d. S. Rotta (2015). Estimation of chlorophyll-a concentration and the trophic state of the Barra Bonita hydroelectric reservoir using OLI/Landsat-8 images. *International journal of environmental research and public health* 12(9), 10391–10417.
- Wetzel, R. G. (2001). Structure and productivity of aquatic ecosystems. In R. G. Wetzel (Ed.), *Limnology: lake and river ecosystems*, Chapter 8, pp. 129–150. San Diego: Gulf Professional Publishing.
- Wilkie, C. J., C. A. Miller, E. M. Scott, R. A. O'Donnell, P. D. Hunter, E. Spyarakos, e A. N. Tyler (2019). Nonparametric statistical downscaling for the fusion of data of different spatiotemporal support. *Environmetrics* 30(3), e2549.
- Xiang, B., J.-W. Song, X.-Y. Wang, e J. Zhen (2015). Improving the accuracy of estimation of eutrophication state index using a remote sensing data-driven method: A case study of Chaohu Lake, China. *Water SA* 41(5), 753–761.
- Xiong, J., C. Lin, R. Ma, e Z. Cao (2019). Remote sensing estimation of lake total phosphorus concentration based on MODIS: A case study of Lake Hongze. *Remote Sensing* 11(17), 2068.
- Xu, X., X. Huang, Y. Zhang, e D. Yu (2018). Long-term changes in water clarity in Lake Liangzi determined by remote sensing. *Remote sensing* 10(9), 1441.
- Xu, Y., B. Qin, G. Zhu, Y. Zhang, K. Shi, Y. Li, Y. Shi, e L. Chen (2019). High temporal resolution monitoring of suspended matter changes from GOCE measurements in Lake Taihu. *Remote Sensing* 11(8), 985.

- Yepez, S., A. Laraque, J. M. Martinez, J. De Sa, J. M. Carrera, B. Castellanos, M. Gallay, e J. L. Lopez (2018). Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River (Venezuela). *Comptes Rendus Geoscience* 350(1-2), 20–30.
- Zeng, C. e C. Binding (2019). The effect of mineral sediments on satellite chlorophyll-a retrievals from line-height algorithms using red and near-infrared bands. *Remote Sensing* 11(19), 2306.
- Zhang, Y., X. Liu, B. Qin, K. Shi, J. Deng, e Y. Zhou (2016). Aquatic vegetation in response to increased eutrophication and degraded light climate in Eastern Lake Taihu: Implications for lake ecological restoration. *Scientific reports* 6(1), 1–12.
- Zhao, Y., Q. Shen, Q. Wang, F. Yang, S. Wang, J. Li, F. Zhang, e Y. Yao (2020). Recognition of water colour anomaly by using hue angle and Sentinel 2 image. *Remote Sensing* 12(4), 716.

APÊNDICES

APÊNDICE A – Síntese dos métodos utilizados em sensoriamento remoto e qualidade da água

A Tabela 1 apresenta uma síntese dos métodos mais utilizados descrito pela literatura recente levantados por meio do banco de dados *Scopus* (palavras-chave *water quality* e *remote sensing*, filtrando estudos de caso que contemplam ambientes de águas continentais).

Tabela 1: Síntese das abordagens utilizadas entre os anos de 2000 e 2020 para sensoriamento remoto da qualidade de águas continentais.

Autor(es)	Tipo de corpo d'água	Instrumento/Sensor	Método (E/A)	Parâmetro
Kupssinskü <i>et al.</i> (2020)	Lago; Reservatório	Sentinel-2/MSI UAV	E	Chl-a TSM
Li <i>et al.</i> (2020)	Lago	UAV	–	Chl-a TSM Temperatura
Pahlevan <i>et al.</i> (2020)	Lago	Sentinel-2/MSI Sentinel-3/OLCI	E	Chl-a
Uudeberg <i>et al.</i> (2020)	Lago	Sentinel-2/MSI Sentinel-3/OLCI	E	Chl-a TSM CDOM SDD
Flores-Anderson <i>et al.</i> (2020)	Lago	EO-1/Hyperion	E	Chl-a
Soomets <i>et al.</i> (2020)	Lago	Sentinel-2/MSI Sentinel-3/OLCI	E	Chl-a TSM CDOM SDD

Li <i>et al.</i> (2020)	Lago	Landsat-8/OLI/TIRS	E	Chl-a COD DO Temperatura pH Turbidez TN TP
Eugenio <i>et al.</i> (2020)	Lagoa	WorldView-3 AHS UAV	A	Chl-a
Van Nguyen <i>et al.</i> (2020)	Lago	MERIS	E	Chl-a
Sòria-Perpinyà <i>et al.</i> (2020)	Lagoa	Sentinel-2/MSI	E	PC
Peppa <i>et al.</i> (2020)	Lago	Sentinel-2/MSI	E	Chl-a
Bresciani <i>et al.</i> (2020)	Lago	Sentinel-2/MSI Sentinel-3/OLCI	E	Chl-a
Silva <i>et al.</i> (2020)	Reservatório	Landsat-8/OLI Sentinel-2/MSI	E	Chl-a Turbidez TSM
Avdan <i>et al.</i> (2019)	Barragem	RapidEye/REIS	A	Condutividade TSM SDD Turbidez
Cao <i>et al.</i> (2019)	Lago	Aqua/MODIS	E	TSM
Liu e Wang (2019)	Lago	MERIS	A	SDD
Zeng e Binding (2019)	Lagoa	Sentinel-3/OLCI	A	Chl-a
Ogashawara (2019)	Lago	Sentinel-3/OLCI	E	Chl-a PC
Son e Wang (2019)	Lago	VIIRS	A	Turbidez
Wilkie <i>et al.</i> (2019)	Lago	MERIS	A	Chl-a
Xu <i>et al.</i> (2019)	Lago	GOCI	E	TSM
Elhag <i>et al.</i> (2019)	Barragem	Sentinel-2/MSI	E	Chl-a TN Turbidez
Vundo <i>et al.</i> (2019)	Lago	MERIS	A	SDD

Pu <i>et al.</i> (2019)	Lago	Landsat-8/OLI	A	pH DO COD TN
Xiong <i>et al.</i> (2019)	Lago	Aqua/MODIS	A	TP
Chelotti <i>et al.</i> (2019)	Reservatório	Landsat-8/OLI Aqua/MODIS	E	TSM
Anspere e Alikas (2019)	Lago	Sentinel-2/MSI	E	Chl-a
Hansen e Williams (2018)	Lago; Reservatório	Landsat-5/TM Landsat-7/ETM+	E	Chl-a
Bresciani <i>et al.</i> (2018)	Lago	Landsat-8/OLI Sentinel-2/MSI	A	Chl-a
Blix <i>et al.</i> (2018)	Lago	Sentinel-3/OLCI	E	Chl-a CDOM TSM
Bonansea <i>et al.</i> (2018)	Reservatório	Landsat-5/TM Landsat-7/ETM+ Landsat-8/OLI	E	Chl-a
Abdelmalik (2018)	Lago	Terra/ASTER	E	Temperatura Turbidez pH Salinidade TSM Condutividade Alcalinidade TOC Orto-fósforo
Xu <i>et al.</i> (2018)	Lago	Landsat-7/ETM+ Landsat-8/OLI	E	SDD
Odermatt <i>et al.</i> (2018)	Lago; Reservatório	MERIS	E	Chl-a TSM Turbidez
Lehmann <i>et al.</i> (2018)	Lago	Landsat-8/OLI	E	Cor
Pyo <i>et al.</i> (2018)	Reservatório	AHS/AISA	E	Chl-a PC TSM

Markogianni <i>et al.</i> (2018)	Lago	Landsat-8/OLI	E	Chl-a Nutrientes
Tu <i>et al.</i> (2018)	Lago	Landsat-5/TM Landsat-7/ETM+ Landsat-8/OLI	E	TSM TN
Markert <i>et al.</i> (2018)	Bacia	Landsat-5/TM Landsat-7/ETM+ Landsat-8/OLI	E	TSM
Binding <i>et al.</i> (2018)	Lago	MERIS	E	Chl-a
Veronez <i>et al.</i> (2018)	Lago	UAV	E	TSM DOM
Sabat-Tomala <i>et al.</i> (2018)	Reservatório	HySpex	E	Chl-a Turbidez TSM CDOM SDD TP
Malahela <i>et al.</i> (2018)	Barragem	Landsat-8/OLI	E	Chl-a
Torbick <i>et al.</i> (2018)	Lago	Landsat-7/ETM+ Landsat-8/OLI	A	PC
Watanabe <i>et al.</i> (2018)	Reservatório	Landsat-8/OLI Sentinel-2/MSI	E	Chl-a
Coelho <i>et al.</i> (2017)	Reservatório	Landsat-8/OLI RapidEye/REIS	E	Chl-a CDOM
Robert <i>et al.</i> (2017)	Lago	Landsat-7/ETM+ Landsat-8/OLI Aqua/Terra/MODIS	E	TSM Turbidez
Li <i>et al.</i> (2017)	Lago	Landsat-7/TIR	E	Temperatura
Rodrigues <i>et al.</i> (2017)	Reservatório	Landsat-8/OLI Sentinel-2/MSI	A	SDD
Ha <i>et al.</i> (2017)	Lago	Sentinel-2/MSI	E	Chl-a
Quang <i>et al.</i> (2017)	Lagoa	Landsat-8/OLI	E	Turbidez
Chen <i>et al.</i> (2017)	Lago	Landsat-8/OLI	E	CDOM

Bresciani <i>et al.</i> (2017)	Lago	MERIS Landsat-8/OLI Proba-1/CHRIS AHS/MIVIS AHS/APEX	A	Chl-a
Bertani <i>et al.</i> (2017)	Lago	Aqua/MODIS MERIS SeaWiFS	E	Cianobactéria
Markelin <i>et al.</i> (2017)	Lago	AHS/AisaFENIX	A	Chl-a
Dörnhöfer <i>et al.</i> (2016)	Lago	Sentinel-2/MSI	A	CDOM TSM
Chen <i>et al.</i> (2016)	Lago	Terra/MODIS	E	TSM
Philipson <i>et al.</i> (2016)	Lago	MERIS	E	Chl-a CDOM TSM
Zhang <i>et al.</i> (2016)	Lago	Aqua/MODIS	E	Chl-a SDD TSM TN TP
Barrett e Frazier (2016)	Lago	Landsat-5/TM Landsat-7/ETM+	E	Chl-a Turbidez
Kutser <i>et al.</i> (2016)	Lago	Landsat-8/OLI Sentinel-2/MSI	E	CDOM
Toming <i>et al.</i> (2016)	Lago	Sentinel-2/MSI	E	Chl-a CDOM Cor DOC
Torbick e Corbiere (2015)	Lago	Landsat-8/OLI RapidEye/REIS Proba-1/CHRIS	E	Chl-a PC
Watanabe <i>et al.</i> (2015)	Reservatório	Landsat-8/OLI	E	Chl-a
Politi <i>et al.</i> (2015)	Lago	Aqua/Terra/MODIS	E	Chl-a SDD
Van der Merwe e Price (2015)	Lago	UAV	E	Cianobactéria

Palmer <i>et al.</i> (2015)	Lago	MERIS	E	Chl-a
Xiang <i>et al.</i> (2015)	Lago	Terra/MODIS	E	Chl-a SDD TN COD TP
Matthews e Bernard (2015)	Variados	MERIS	E	Chl-a Cianobactéria
Bonansea <i>et al.</i> (2015)	Reservatório	MERIS	E	Chl-a
Pinardi <i>et al.</i> (2015)	Lago	AHS/MIVIS AHS/APEX Proba-1/CHRIS	E	Chl-a
Liu <i>et al.</i> (2015)	Lago; Rio	IKONOS	E	TN TP
Giardino <i>et al.</i> (2014)	Lago	Aqua/MODIS Landsat-8/OLI RapidEye/REIS	A	Chl-a
Ogashawara e Moreno-Madriñán (2014)	Lago	Aqua/MODIS	E	Chl-a
Mishra e Mishra (2014)	Lago	MERIS	E	Chl-a PC
Wang <i>et al.</i> (2014)	Lago	ALOS/Palsar	E	pH DO COD TSM TN TP
Ogashawara <i>et al.</i> (2014)	Reservatório	Terra/MODIS	E	Chl-a
Torbick <i>et al.</i> (2014)	Lago	Landsat-5/TM	E	Chl-a SDD TN

Huo <i>et al.</i> (2014)	Variados	Landsat-7/ETM+	A	Chl-a SDD TN COD TP
Ogashawara <i>et al.</i> (2014)	Reservatório	Landsat-5/TM Landsat-7/ETM+	E	Cianobactéria
Novo <i>et al.</i> (2013)	Reservatório	Landsat-5/TM	E	Chl-a
Cheng <i>et al.</i> (2013)	Lago	Hyperion Proba-1/CHRIS	E	Chl-a
Bresciani <i>et al.</i> (2013)	Lago	MERIS	E	Cianobactéria
Cui <i>et al.</i> (2013)	Lago	Terra/Aqua/MODIS	E	TSM
Bresciani <i>et al.</i> (2012)	Lago	MERIS	E	Chl-a
Stefouli e Charou (2012)	Lago	MERIS Landsat-5/TM	E	Chl-a SDD
Knight e Voth (2012)	Lago	Terra/MODIS	E	SDD
Potes <i>et al.</i> (2012)	Reservatório	MERIS	E	Turbidez
Wang <i>et al.</i> (2012)	Lago	JER-1 SAR	E	pH DO COD BOD TSM TN TP
Alcântara <i>et al.</i> (2011)	Reservatório	Terra/MODIS	E	Temperatura
Binding <i>et al.</i> (2011)	Lago	MERIS	E	Chl-a
Hadjimitsis e Clayton (2011)	Variados	Landsat-5/TM Landsat-7/ETM+	E	Chl-a POC
Jiang <i>et al.</i> (2010)	Reservatório	Landsat-5/TM ALOS/Palsar P6	A	Chl-a TSM Absorção de matéria não-pigmentada

Alparslan <i>et al.</i> (2010)	Barragem	Landsat-5/TM	E	Chl-a TSM Turbidez TN TP
Giardino <i>et al.</i> (2010)	Lagoa	MERIS	E	Chl-a CDOM
Mancino <i>et al.</i> (2009)	Lago	Landsat-5/TM	E	Chl-a SDD
Alparslan <i>et al.</i> (2009)	Lago	Landsat-5/TM SPOT IRS-1C/D LISS	E	Chl-a TN TP Turbidez COD BOD
Salama <i>et al.</i> (2009)	Lago	AHS MERIS Terra/ASTER	A	Chl-a TSM
Odermatt <i>et al.</i> (2008)	Lago	MERIS	E	Chl-a
Menken <i>et al.</i> (2006)	Lago	Aqua/MODIS	E	Chl-a CDOM Turbidez
Brezonik <i>et al.</i> (2005)	Lago	Landsat-5/TM	E	Chl-a CDOM
Kutser <i>et al.</i> (2005)	Lago	EO-1/ALI	E	CDOM

APÊNDICE B – Tabelas complementares

As Tabelas a seguir complementam os resultados alcançados nas campanhas realizadas em Julho/2019 ([Curtarelli \(2020\)](#), [2](#)), Outubro/2019 ([3](#) e [4](#)), Maio/2020 ([5](#)), Maio/2021 ([6](#)), Junho/2021 ([7](#)), Agosto/2021 ([8](#)), Setembro/2021 ([9](#)) e Outubro/2021 ([10](#)).

Tabela 2: Valores obtidos dos parâmetros opticamente ativos avaliados em Julho/2019 por [Curtarelli \(2020\)](#).

Ponto	Secchi (cm)	Chl-a ($\mu\text{g/L}$)
1	4,42	3,74
2	3,78	3,5
3	3,22	5,7
4	4,22	4,24
5	3,99	3,73
6	4,36	—
7	3,6	—
8	2,81	—

Tabela 3: Valores obtidos dos parâmetros opticamente ativos avaliados em Outubro/2019.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (FNU)	Secchi (cm)	Temp. ($^{\circ}$)
1	1,94	0,24	599	0,24
2	1,78	0,20	484	0,20
3	2,08	0,65	448	0,65
4	2,15	0,32	440	0,32
5	1,63	0,53	282	0,53
6	8,10	1,06	244	1,06
7	5,68	0,53	242	0,53
8	7,76	1,11	237	1,11
9	4,40	1,04	215	1,04
10	4,38	1,10	211	1,10
11	5,35	1,08	243	1,08
12	4,30	1,08	219	1,08
13	3,82	1,11	199	1,11

Tabela 4: Valores obtidos dos parâmetros NOA avaliados em Outubro/2019.

Ponto	OD (mg/L)	pH	CT (mg/L)	COT (mg/L)	Condut. (mV)	ORP (mV)
1	7,40	8,20	19,8	13,3	61,5	447,6
2	7,45	8,08	17,3	10,8	64,1	460,2
3	7,76	8,30	21,8	15,2	77,5	449,1
4	7,68	8,36	34,2	27,6	81,1	444,0
5	7,81	8,51	16,8	9,9	90,0	438,7
6	7,99	8,54	22,0	15,0	92,0	442,5
7	8,17	8,60	23,9	16,8	96,8	426,5
8	7,66	8,41	28,9	21,9	84,2	440,9
9	7,76	8,34	50,4	43,3	79,7	452,3
10	7,68	8,31	28,8	21,7	77,9	455,9
11	7,73	8,30	25,5	21,4	77,2	459,0
12	7,58	8,26	62,7	55,7	75,1	464,2
13	7,62	8,29	29,9	22,8	66,8	468,0

Tabela 5: Valores obtidos dos parâmetros opticamente ativos avaliados em Maio/2020.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	0,66	6,27	180
2	0,60	2,21	280
3	0,61	2,04	275
4	0,72	0,98	315
5	0,83	—	515
6	0,66	0,72	400
7	0,77	0,88	375
8	0,73	1,61	285
9	0,70	1,70	270
10	0,84	1,84	280
11	0,75	1,88	265
12	0,74	1,91	260
13	0,81	1,02	420

Tabela 6: Valores obtidos dos parâmetros opticamente ativos avaliados em Maio/2021.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	1,19	0,99	400
2	0,95	0,97	425
3	0,88	1,18	370
4	1,51	1,19	375
5	1,11	1,26	350
6	0,98	1,51	310
8	1,17	1,04	360
9	1,33	0,81	0*
10	0,74	1,40	375
11	1,38	1,38	300
12	1,93	1,40	290
13	1,66	1,36	270
14	1,64	1,41	280
15	1,45	1,44	290
16	2,04	1,58	260
17	1,48	1,60	260
18	2,17	1,81	240
19	1,31	1,45	260
20	1,05	1,46	300
21	1,12	1,39	300
22	1,34	1,24	310
23	1,49	1,35	310
24	1,49	1,52	250
25	1,70	1,44	270
26	2,11	1,62	260
27	3,16	1,93	220
28	3,06	2,14	230
29	3,06	1,95	240
30	2,37	2,51	220

*Disco de Secchi atingiu o fundo do reservatório.

Tabela 7: Valores obtidos dos parâmetros opticamente ativos avaliados em Junho/2021.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	1,55	1,02	290
2	1,45	0,53	280
3	2,11	1,24	280
4	1,44	0,77	355
5	1,61	0,75	320
6	1,35	0,58	475
7	1,54	0,56	320
8	1,43	0,61	300
9	0,74	1,31	290
10	0,68	1,38	290
11	0,68	0,98	340
12	0,71	1,06	320
13	0,66	1,31	330
14	0,56	1,03	350
15	1,15	0,84	315
16	1,42	0,80	320
17	1,08	0,73	330
18	1,17	0,67	380
19	1,12	0,65	380
20	1,03	0,77	380
21	1,22	0,82	340
22	1,30	0,88	350

Tabela 8: Valores obtidos dos parâmetros opticamente ativos avaliados em Agosto/2021.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	1,20	0,51	550
2	1,09	0,52	480
3	1,38	0,45	420
4	1,23	0,51	420
5	0,94	0,51	400
6	1,08	0,49	460
7	1,23	0,54	390
8	0,97	0,53	390
9	0,92	0,47	420
10	0,86	0,49	410
11	0,81	0,60	400
12	0,91	0,51	420
13	1,61	0,47	400
14	1,24	0,58	410
15	1,30	0,64	390
16	1,08	0,55	390
17	1,29	1,04	340
18	1,23	1,02	360
19	1,08	0,72	370
20	1,04	0,71	360
21	1,05	0,60	350
22	1,15	0,76	320
23	0,89	0,66	390
24	1,34	0,74	340
25	1,34	1,06	310
26	1,14	0,98	310
27	1,01	1,16	300
28	1,17	1,15	290
29	1,09	1,91	220

Tabela 9: Valores obtidos dos parâmetros opticamente ativos avaliados em Setembro/2021.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	2,05	2,73	190
2	2,40	2,73	180
3	2,53	3,08	200
4	2,63	3,41	180
5	2,14	3,23	195
6	1,67	2,76	220
7	1,75	2,91	195
8	1,35	2,63	220
9	1,44	3,64	170
10	1,36	2,46	210
11	2,30	2,52	210
12	1,29	3,35	170
13	1,23	2,08	230
14	1,15	2,92	200
15	1,34	2,29	210
16	1,61	2,50	190
17	1,43	3,10	210
18	1,26	1,60	240
19	1,33	1,36	250
20	2,03	2,44	210
21	1,63	3,00	180
22	1,49	3,67	160
23	1,16	1,04	310
24	1,07	1,18	260
25	0,79	1,06	315
26	0,84	1,15	340

Tabela 10: Valores obtidos dos parâmetros opticamente ativos avaliados em Outubro/2021.

Ponto	Chl-a ($\mu\text{g/L}$)	Turbidez (NTU)	Secchi (cm)
1	12,41	1,27	290
2	12,36	1,42	310
3	13,09	1,39	290
4	12,96	1,39	260
5	13,07	1,29	280
6	13,03	1,34	280
7	12,84	1,55	300
8	12,59	1,55	280
9	12,51	1,64	280
10	12,66	1,67	260
11	12,66	1,48	300
12	12,42	1,31	310
13	12,48	1,36	240
14	12,66	1,40	270
15	12,59	3,67	220
16	12,74	1,29	260
17	13,40	1,81	250
18	13,09	2,77	240
19	13,43	1,63	260
20	13,47	1,27	310
21	13,61	1,25	290
22	13,62	2,42	230
23	13,54	2,51	220
24	14,22	2,88	230
25	13,88	1,97	240
26	14,15	1,59	270
27	14,85	1,48	280
28	13,07	2,06	240
29	13,14	1,90	260
30	13,94	1,81	240
31	13,75	1,73	260
32	13,30	1,80	260
33	13,34	1,19	320
34	12,67	1,36	300
35	13,51	1,80	250

ANEXOS

ANEXO A – Artigo: Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors

PIZANI, F.M.C.; MAILLARD, P.; FERREIRA, A.F.F. ; AMORIM, C.C.. Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, v. V-3-2020, p. 401-408, 2020.

ESTIMATION OF WATER QUALITY IN A RESERVOIR FROM SENTINEL-2 MSI AND LANDSAT-8 OLI SENSORS

Fernanda M. C. Pizani^{1*}, Philippe Maillard¹, Adrielly F. F. Ferreira², Camila C. de Amorim²

¹ Department of Geography, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil
fm.coelho@yahoo.com.br - philippermaillard@yahoo.com.br

² Department of Sanitary and Environmental Engineering, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil
adrielly.fonseca@gmail.com - camila@desa.ufmg.br

Commission III, WG III/9ICWG

KEY WORDS: Water Quality, Statistical Models, Regression Analysis, Reflectance, Landsat-8 OLI, Sentinel-2 MSI

ABSTRACT:

The low operational cost of using freely available remote sensing data is a strong incentive for water agencies to complement their field campaigns and produce spatially distributed maps of some water quality parameters. The objective of this study is to compare the performance of Sentinel-2 MSI and Landsat-8 OLI sensors to produce multiple regression models of water quality parameters in a hydroelectric reservoir in Brazil. Physical-chemistry water quality parameters were measured *in loco* using sensors and also analysed in laboratory from water samples collected simultaneously. The date of sampling corresponded to the almost simultaneous overflight of Sentinel-2B and Landsat-8 satellites which provided a means to perform a fair comparison of the two sensors. Four optically active parameters were considered: chlorophyll-a, Secchi disk depth, turbidity and temperature (the latter using Landsat-8 TIR sensor). Other six optically non-active parameters were also considered. The multiple regression models used the spectral reflectance bands from both sensors (separately) as predictors. The reflectance values were based on averaging kernels of 30 m and 90 m. Stepwise variable selection combined with *a priori* knowledge based on other studies were used to optimize the choice of predictors. With the exception of temperature, the other optically active parameters yielded strong regression models from both the Sentinel and Landsat sensors, all with $r^2 > 0.75$. The models for the optically non-active parameters produced less striking results with r^2 as low as 0.03 (temperature) and as high or better than > 0.8 (pH and Dissolved oxygen).

1. INTRODUCTION

The use of remote sensing techniques to assess water resources started in the 60's with the availability of the first digital satellite images (Mertes et al., 2004). Initially, it was the presence of chlorophyll-a (chl-a) in the water and the water surface temperature that motivated the use of such techniques and also motivated the study of optical properties of water components to determine if these water quality related parameters could be estimated remotely (Mishra et al., 2017). It is the relation between the spectral behaviour of water and the presence of optically active components (OAC) that make remote sensing and digital image processing valuable tools to monitor the quality of water. The fact that water has a very distinctive spectral signature, characterised mostly by its strong absorption in the near and shortwave infrared makes it easily detectable using these wavelengths (Teodoro, 2016). The interaction between solar radiation and OAC alters the spectral properties of water and can therefore be used as indicators of water quality (Barbosa et al., 2019).

Traditional methods for monitoring water quality parameters involving the extraction and analysis of water samples are known to consume a lot of time and resources (Karaoui et al., 2019, Yepez et al., 2018) and demand very specialised labour (Giardino et al., 2010), even more so for large reservoirs. In comparison, remotely monitoring some water quality parameters using satellite images can largely reduce these costs while providing spatially distributed estimates with a higher

frequency in time. A large number of satellite missions systematically acquire image and point data of the Earth with a variety of spectral and spatial resolution. Some of these satellites can be used to estimate water level through radar altimetry while others equipped with optical sensors produce image data that can be used to estimate water quality parameters. Within the realm of missions providing systematic optical image acquisition, the Landsat (National Air and Space Administration - NASA) and Sentinel-2 (European Space Agency - ESA) programs offer high resolution optical image products in a free and open data policy. The Landsat-8 satellite (launched in 2013) is equipped with the Optical Land Imager (OLI) and offers a revisit frequency of 16 days while Sentinel-2A (launched in 2015) and 2B (launched in 2017) is a twin satellite constellation equipped with the MultiSpectral Imager (MSI) providing together image data every 5 days almost anywhere.

Recent research in many parts of the world involving water quality have made use of data from Landsat-8 (Liu, Wang, 2019, González-Márquez et al., 2018, Mushtaq, Nee Lala, 2017), Sentinel-2 (Karaoui et al., 2019, Potes et al., 2018) or both (Dutra et al., 2019, Yadav et al., 2019, Watanabe et al., 2018). Table 1 gives a list of some of these authors with the sensor they used and the parameters they analysed. In parallel to the development of remote sensing applications for water quality, spatial modelling together with statistical inference have become common use for creating distributed models of bio-optical parameters of water quality. Correlation as well as simple and multiple regression analysis have been used widely for this purpose (Mainali et al., 2019).

*Corresponding author

Author	Parameter	Sensor
Liu, Wang (2019)	Turbidity	OLI
González-Márquez et al. (2018)	Turbidity, DO, conductivity, pH, depth	OLI
Mushtaq, Nee Lala (2017)	pH, COD, DO, alkalinity, hardness, chloride, TDS, TSS, turbidity, conductivity, phosphate	OLI
Karaoui et al. (2019)	OD, nitrate, total phosphorus, phosphate, chl-a	MSI
Potes et al. (2018)	Chl-a, turbidity, cyanobacteria	MSI
Dutra et al. (2019)	Chl-a, CDOM, TSS, turbidity	OLI & MSI
Yadav et al. (2019)	Chl-a	OLI & MSI
Watanabe et al. (2018)	Chl-a	OLI & MSI

Table 1. Water quality studies using MSI, OLI or both.

In Brazil, the legislation requires managing agencies of large reservoirs to periodically monitor a number of water quality parameters that they must make publicly available to society, regardless of their use (water supply, energy, leisure, etc.). This is the case of the Três Marias Reservoir in Minas Gerais constructed in the 50's mostly for regulating the discharge of the São Francisco River and to generate hydroelectric power (Cachapuz, 2006). Up to now, this has been performed by traditional *in situ* methods of water sampling and laboratory analysis. The time and efforts allocated to *in situ* monitoring hinders actions of environmental preservation and control in a satisfactory time frame, especially given the peculiarities and size of such reservoirs (Karaoui et al., 2019).

The high costs associated with this practice has brought the CEMIG (*Companhia Energética de Minas Gerais*) to investigate alternate methods of monitoring using remote sensors both on satellite and aerial platforms. The objective is to optimise the *in situ* campaigns and to reduce the number of parameters requiring laboratory analysis and to provide a distributed version of some of these parameters, mostly for the OACs. Within this general workframe, our objective is to evaluate which parameters and to what extent the sensors on-board the Landsat-8 and Sentinel-2 satellite can provide satisfactory estimates. In this study we used a fully empirical approach through multiple regression to create models of both OAC and NOAC (Non Optically Active Components) for the particular case of the Três Marias Reservoir.

2. METHODOLOGY

2.1 Study Area

The Três Marias Reservoir is located within the São Francisco Basin in Central Minas Gerais ($18^{\circ}10' S$ e $19^{\circ}00' S$; $44^{\circ}50' W$ e $45^{\circ}35' W$). It flooded an area of 1090 km^2 at its maximum level (576.2 m) to contain approximately 20 Gm^3 of water. With these dimensions, Três Marias occupies the ninth and tenth place in ranking of Brazilian reservoirs in terms of area and volume respectively (von Sperling, 1999). The reservoir is

characterised by a highly dendritic shape (Figure 1) and is inserted in a two seasons semi-humid climate, one dry winter season and one wet summer receiving most (>85%) of the 1440 mm of rain yearly.

2.2 Aquisition of *In Situ* Limnological Data

The water sampling was done between 8H00 and 14H00 local time on 4 October 2019. The sampling locations were selected considering a number of factors including depth, affluents, land use of surrounding areas (presence of agriculture and urban areas) and pisciculture activities. It was also important to do the sampling with shortest time possible to reduce possible changes in the water properties. The date was selected for corresponding to the special condition of having both Landsat-8 and Sentinel-2B overflying the reservoir within about 10 minutes, a situation that only occurs every 80 days. On that particular day, the sky was completely free of clouds and atmospheric attenuation was considered almost null.

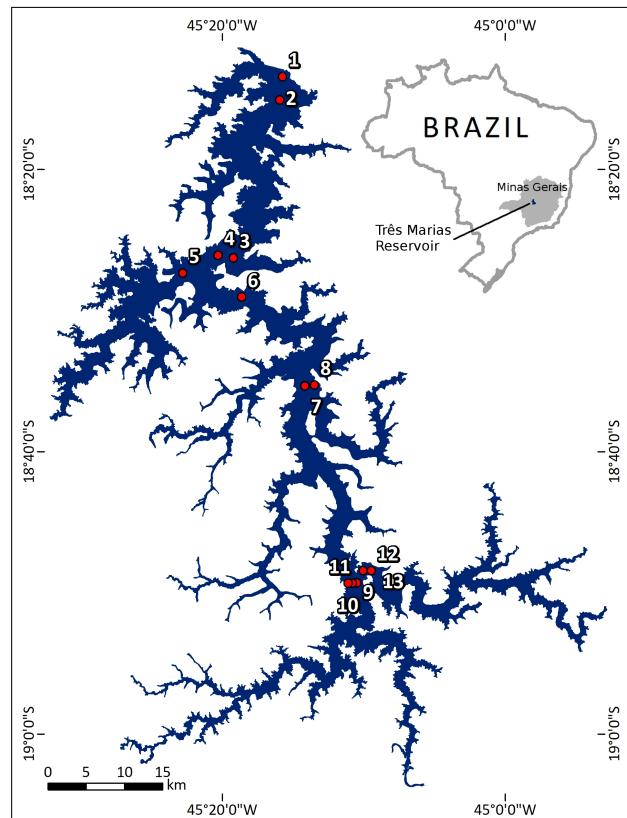


Figure 1. Três Marias Reservoir with the location of the 13 sampling points.

During the sampling of the 13 points, some parameters were measured *in loco* using specialised sensors: dissolved oxygen (DO), pH, temperature (T°), Secchi disk depth, turbidity, colour, conductivity and oxidation-reduction potential (ORP). The remaining parameters were analysed in laboratory the following days and included: chlorophyll-a, -b, -c, total carbon (TC), organic carbon (OC), nitrogen (N), phosphorous (P), chlorate, sulphate, total iron and total suspended solid. For these analyses, about nine litres of water were collected at each sampling point.

The parameters directly liable to be monitored through optical remote sensing were Secchi disk depth, turbidity, chlorophyll-

a (chl-a) and colour. The thermal bands of Landsat-8 (TIRS) were also considered to estimate the surface water temperature. Some of the remaining parameters could also be estimated through statistical inference as indicators of the dynamic processes within the water body. These depend on indirect relation between the OAC and their NOAC counterparts and would only be applicable to the particular situation of the reservoir on the day of sampling. Only some of these parameters will be analysed here.

2.3 Remote Sensing Data Acquisition and Pre-processing

Our study used freely available Level 2 data from the Landsat-8 (<https://earthexplorer.usgs.gov>) and Sentinel-2B (<https://sentinel.esa.int>) satellites. Level 2 image data are pre-processed to include top-of-atmosphere (TOA) radiometric and geometric corrections and are supplied as spectral reflectance data. The Sentinel-2B satellite overflew the reservoir at 10:12:49 and Landsat-8 at 10:03:31 local time. Both images had less than 1% of cloud and no atmospheric interference of any kind could be observed.

The acquired images were converted from TOA reflectance to bottom-of-atmosphere (BOA) reflectance meaning that any atmospheric interference in the spectral response has been reduced to a minimum. The Sentinel-2B image was converted using the MAJA (MACCS ATCOR Joint Algorithm (Lonjou et al., 2016)) pre-processing supplied by the *Centre National d'Études Spatiales* (CNES). The Landsat-8 image were processed using the Landsat-8 Surface Reflectance Code (LASRC (Landsat-USGS, 2018)) provided by the United States Geological Service (USGS). The Level 2 Landsat image does not come with the thermal infrared sensor (TIRS) bands, so, in this case the Level 1 image was used. For the temperature, because of reported radiometric errors of $\pm 1^{\circ}\text{K}$ and $\pm 2^{\circ}\text{K}$ for Landsat-8 TIRS bands 10 and 11 respectively (USGS, 2019), only band 10 was used to produce water surface temperature data using Equation 1.

$$\rho\lambda = \frac{M_\rho Q_{cal} + A_\rho}{\cos(90^\circ - \theta_{SE})} \quad (1)$$

where $\rho\lambda$ = Top Of Atmosphere (TOA) planetary reflectance
 M_ρ = Band-specific multiplicative rescaling factor from the metadata
 Q_{cal} = Quantized and calibrated standard product pixel values (DN)
 A_ρ = Band-specific additive rescaling factor from the metadata
 θ_{SE} = Local sun elevation angle

To simplify the extraction of spectral data for building the statistical models, all Sentinel-2B 20 m bands and 60 m band 1 (coastal) were resampled to 10 m, making them all compatible within the same dataset. The same was done with Landsat-8 band 10 (TIRS) but at 30 m in this case. The spectral information (reflectance and temperature) was extracted considering a neighbouring kernel of 3 pixels \times 3 pixels (30 m \times 30 m for the MSI sensor and 90 m \times 90 m for the OLI sensor) to account for any imprecision of the navigation GNSS or the image geometry but also for the drifting of the boat during the few minutes of collecting. In addition an extraction kernel of 90 m \times 90 m was also created for the Sentinel-2B data so that a fair comparison

can be made with the Landsat-8 data. The extracted spectral values were combined with the water sampling data in the same spreadsheets for analysis.

2.4 Regression models

Multiple linear regressions were produced with *RStudio* (v. 1.5.5109) to analyse the relationship between some of the water quality parameters and the mean reflectance values of the three analysis kernels (two for Sentinel-2B, one for Landsat-8). At this stage, a completely empirical approach was adopted which can yield robust models in many cases (Matthews, 2011). The selection of predictors was performed using two different approaches:

- The first approach used a hybrid bidirectional stepwise method by which the predictors are iteratively selected first by addition (forward) and then by removing the ones having a poor contribution (backward) (James et al., 2013);
- The second approach used predictors most quoted in previous work by other authors, many of which were quoted in the Introduction section. This was performed in an attempt to generate comparable results. Only the OACs were considered for this approach.

The adoption of this double strategy aimed at creating models with a reduced number of predictors as well as being more objective while avoiding over-fitting problems a too numerous number of predictors would create.

2.5 Model Validation and Accuracy Estimation

Four evaluation metrics were used to characterise the performance of the models. The Coefficient of Determination (r^2) gives an estimate of the proportion of variance explained by the model. The r^2 is only a valid estimator if its significance is high. A significance level of 95% ($p < 0.05$) was used here. The Mean Absolute Error (MAE) gives an idea of the average vertical distance between the predicted and the observed value. The Root Mean Square Error (RMSE) and Normalised Root Mean Square Error (NRMSE) are typically used to evaluate models but are rather sensitive to outliers.

3. RESULTS AND DISCUSSION

3.1 Water Quality in the Três Marias Reservoir

The sampling point results obtained both *in loco* and in the post-campaign laboratory are presented in Table 2 and 3. Of the ten variable presented in these tables, only four are considered optically active (Table 2).

A rapid analysis of the 13 sampling points collected in the reservoir reveals a decrease of the water quality from the North end towards the South end which is upstream. In particular the two affluents (São Francisco River on the left and Paraopeba River on the right) appear much more turbid than the rest of the points. Conversely, the two northernmost points (1 and 2) show a Secchi disk transparency of almost 6 m (turbidity of 0.2 NTU).

Sampling points 3 to 6 are all within the central-north portion of the reservoir and are characterised by the presence of fish farms (pisciculture) in the reservoir's marginal water and by intense

Sampling Point	Chl-a µg/L	Temp. C°	Secchi cm	Turbidity NTU
1	1.94	27.2	600	0.24
2	1.78	27.0	484	0.20
3	2.08	26.6	449	0.65
4	2.15	28.0	441	0.32
5	1.63	28.3	283	0.53
6	8.10	27.6	244	1.06
7	5.68	28.4	242	0.53
8	7.76	28.4	238	1.11
9	4.40	27.6	216	1.04
10	4.38	27.8	212	1.10
11	5.35	28.2	244	1.08
12	4.30	28.0	219	1.08
13	3.82	27.9	199	1.11

Table 2. Values obtained for the four optically active component parameters.

Sampling Point	DO mg/L	pH	TC mg/L	OC mg/L	Conduc. mV	ORP mV
1	7.40	8.20	19.8	13.3	61.5	447.6
2	7.45	8.08	17.3	10.8	64.1	460.2
3	7.76	8.30	21.8	15.2	77.5	449.1
4	7.68	8.36	34.2	27.6	81.1	444.
5	7.81	8.51	16.8	9.9	90.0	438.7
6	7.99	8.54	22.0	15.0	92.0	442.5
7	8.17	8.60	23.9	16.8	96.8	426.5
8	7.66	8.41	28.9	21.9	84.2	440.9
9	7.76	8.34	50.4	43.3	79.7	452.3
10	7.68	8.31	28.8	21.7	77.9	455.9
11	7.73	8.30	25.5	21.4	77.2	459.0
12	7.58	8.26	62.7	55.7	75.1	464.2
13	7.62	8.29	29.9	22.8	66.8	468.0

Table 3. Values obtained for the four non optically active component parameters.

agricultural activities (centre pivot) in the areas near the reservoir shore. This is particularly observable at Point 6 which has the greatest values of chl-a ($8.10 \mu\text{g/L}$). Although this concentration of chl-a is much higher than for the remaining samples, this does not constitute a state of eutrophication according to the State Water Agency (IGAM). However it should be mentioned that these measurements were made during the dry season when the water quality is often better.

Two sampling points are located near the northern extremity of an island called Mangabal and also have relatively high concentrations of chl-a compared with the remaining points (except Point 6). Algae and or cyanobacteria were in fact visually observable as can be seen on Figure 2. Although not yet considered a bloom, these observations are good indicators of the necessity to continuously monitor the reservoir's water (Barbosa et al., 2019).

The sampling points 9 through 13 are all located near the confluence between the São Francisco River (9, 10 and 11) and the Paraopeba River (12 and 13). These sample appear to be the worst in terms of water quality. Not only the transparency is poor (Secchi disk depth of 1.9 m) but this is where the highest concentrations of carbon (total carbon or TC) and organic carbon (OC) were recorded and are often indicative of water pol-



Figure 2. The presence of algae and/or cyanobacteria was observed near sampling points 7 and 8.

lution (Moore, 1998). It is also important to emphasize that this stretch of the reservoir presents a turbulent flow, thus differing from the other locations analysed in this article.

3.2 Multiple Regression Results

The first set of multiple regression models were created using the hybrid bi-directional stepwise approach. The second set combined the stepwise approach with *a priori* information from previous authors. After executing the stepwise regression, the poor predictors were removed except if indicated by the reference authors and until the level of significance is above 95%.

The *a priori* selection of predictor bands was based on articles by Yadav et al. (2019), Dutra et al. (2019) Watanabe et al. (2018) and Potes et al. (2018) for the chl-a models. The Secchi disk depth was based on papers from Bonansea et al. (2015), Rodríguez et al. (2014) and Giardino et al. (2010) while turbidity used references from Liu and Wang (2019), González-Márquez et al. (2018) and Mushtaq and Nee Lala (2017). Surface temperature was based on a simple regression between Landsat's thermal band 10 and the temperature measured in the field. Table 4 shows the results for nine parameters for the two Sentinel kernels and 10 parameters for the Landsat one. Table 5 describes the equations resulting from these regression models.

Parameter	MSI: 30×30 m	MSI: 90×90 m	OLI: 90×90 m	Method
Chl-a	B2, B3, B4, B5	B2, B3, B4, B5	B2, B3, B4	Stepwise + <i>a priori</i>
Secchi	B1, B3	B1, B3	B1, B3	Stepwise + <i>a priori</i>
Turbidity	B1, B3	B1, B3	B1, B3	Stepwise + <i>a priori</i>
Temp.	—	—	B10	—
OC	B4, B8	B4, B8	B4, B5	Stepwise
DO	B2, B4, B6, B11	B2, B4, B6, B11	B2, B4, B6, B7	Stepwise
pH	B1, B3, B6, B8	B1, B3, B6, B8	B1, B3, B6, B5	Stepwise
TC	B2, B3, B5, B8	B2, B3, B5, B8	B2, B3, B5	Stepwise
Conduc.	B1, B2, B3, B8	B1, B2, B3, B8	B1, B2, B3, B5	Stepwise
ORP	B1, B4, B6	B1, B4, B6	B1, B4, B5	Stepwise

Table 4. Selection of spectral bands and method used.

The multiple regression models for the optically active components chlorophyll-a, Secchi disk depth and turbidity yielded high

Sentinel-2/MSI - 30×30 m kernels		
Dependent variable	Equation	r ²
Chl-a	26.447 + (-1672.777 * B2) + (266.620 * B3) + (1402.560 * B4) + (-58.610 * B5)	0.71
Secchi	391.9 + (22403.1 * B1) + (-16175.8 * B3)	0.85
Turbidity	0.4329 + (-54.6776 * B1) + (42.4338 * B3)	0.78
pH	12.2621 + (-246.4698 * B1) + (29.4987 * B3) + (300.0727 * B6) + (-140.2648 * B8)	0.89
DO	9.2505 + (-171.0251 * B2) + (236.9708 * B4) + (76.8288 * B6) + (-150.7815 * B11)	0.85
ORP	262.09 + (9550.20 * B1) + (-1922.66 * B4) + (-5096.10 * B6)	0.65
Conduc.	-152.77 + (-1400.65 * B1) + (6477.29 * B2) + (-2380.85 * B3) + (-1755.82 * B8)	0.69
TC	-44.25 + (4558.89 * B2) + (-2865.50 * B3) + (10289.91 * B5) + (-13255.30 * B8)	0.63
OC	-6.427 + (2828.828 * B4) + (-2780.688 * B8)	0.46
Sentinel-2/MSI - 90×90 m kernels		
Dependent variable	Equation	r ²
Chl-a	18.420 + (-1263.615 * B2) + (413.934 * B3) + (52.127 * B4) + (710.274 * B5)	0.75
Secchi	396.3 * (22408.6 * B1) + (-16290.6 * B3)	0.84
Turbidity	0.4532 + (-56.9454 * B1) + (43.5723 * B3)	0.80
pH	11.6424 + (-216.0938 * B1) + (28.5913 * B3) + (368.9336 * B6) + (-239.9383 * B8)	0.79
DO	8.9055 + (-129.5866 * B2) + (192.3651 * B4) * (36.4049 * B6) + (-116.7094 * B11)	0.83
ORP	296.98 + (7568.51 * B1) + (-1567.75 * B4) + (-3717.99 * B6)	0.62
Conduc.	-144.80 + (-2472.14 * B1) + (7325.98 * B2) + (-2567.43 * B3) + (-1486.76 * B8)	0.76
TC	5.676 + (1710.054 * B2) + (-2737.135 * B3) + (14253.121 * B5) + (-14800.586 * B8)	0.49
OC	-4.841 + (2779.807 * B4) + (-2794.718 * B8)	0.45
Landsat-8/OLI - 90×90 m kernels		
Dependent variable	Equation	r ²
Chl-a	15.717 + (-1247.530 * B2) + (192.236 * B3) + (846.290 * B4)	0.67
Secchi	511.9 + (21335 * B1) + (-17343.6 * B3)	0.81
Turbidity	0.2294 + (-59.2739 * B1) + (48.0012 * B3)	0.80
Temperature	-147.6961 + (0.5924 * B10)	0.03
pH	9.9977 + (-110.1097 * B1) + (17.4231 * B3) + (49.6782 * B5)	0.43
DO	9.5867 + (-127.1909 * B2) + (115.4625 * B4) + (-223.5492 * B6) + (227.0583 * B7)	0.69
ORP	316.16 + (7054.50 * B1) + (-903.87 * B4) + (-3313.56 * B5)	0.43
Conduc.	-108.62 + (-7534.79 * B1) + (11877.90 * B2) + (-2931.28 * B3) + (-901.26 * B5)	0.69
TC	-67.62 + (3658.91 * B2) + (3658.91 * B2) + (-166.73 * B3) + (-1225.28 * B5)	0.62
OC	-20.95 + (2577.36 * B4) + (-1444.90 * B5)	0.54

Table 5. Regression equations for the water quality models for the Sentinel-2 using 30x30 kernels (top), 90x90 kernels (middle) and Landsat-8 using 90x90 kernels (bottom).

coefficients of determination (r^2) ranging from 0.75 to 0.85 for both Sentinel and Landsat and for both kernel sizes (30×30 and 90×90). This proves that the spectral bands resulting from the two selection methods are good predictors, especially the MSI instrument with 90×90 kernels.

However, the temperature model produced a very low r^2 value of 0.03. We attribute this poor result mainly to the time difference between the in situ measurements and the time Landsat sensed the scene (\approx 10H00). It is also reported that the Landsat-8 TIR sensor suffers from calibration problems which hinders the absolute conversion from radiance to temperature (Montanaro et al., 2014) but that does not explain the very low r^2 obtained. Applying a radiance-to-temperature transformation would probably be preferable to the statistical inference we used in this article but since we had no usable in situ temperature to validate the data we simply left out the temperature models for future field campaigns when we will acquire temperatures samples within a short time lag close to the satellite sensing time.

The Sentinel-2B MSI sensor produced better results than the Landsat-8 OLI for all parameters except for the carbon (total and organic). The greater number of spectral bands (red edge and near infrared) and shortwave infrared and the finer spectral resolution of bands 3–7 and 8a can probably explain this result. Sentinel's band 1 (coastal) would also be useful because of its potential penetration in the water but has calibration problems that causes a large vertical banding in the images. The two kernel sizes for the MSI results appear to have relatively little effect on the results.

Table 6 shows all the accuracy metrics used to evaluate the models. Although the $p < 0.05$ critical value was used, we observe that many models are under 0.01 (99%) including the chl-a, Secchi disk depth and turbidity for all three kernel size - sensor combinations. The TC model with the MSI sensor (30 m kernel) yielded $p = 0.06$, which could still be considered acceptable with $r^2 = 0.63$. Because the stepwise method was used to remove predictors, it has been suggested that the critical p value could be relaxed (Babyak, 2004). The MAE, RMSE and NRMSE all show the same trend in the values. The MAE is particularly interesting as it gives a more realistic idea of the kind of precision one can expect from these models.

3.3 Relation Between Optically Active and Non-active Parameters

Three of the four optically active components parameters have yielded very good and significant results. These results can also explain some of the good results obtained for the optically non-active parameters such as pH, DO, conductivity and carbon (TC and OC) through indirect relationships.

With r^2 of 0.85, 0.83 and 0.69 for the three kernels (MSI_30, MSI_90 and OLI_90), dissolved oxygen achieved the highest score among the optically non-active parameters. This can be related to the higher concentrations of chlorophyll associated with photosynthesis, hence production of oxygen by chlorophyllian organisms. The pH models achieve r^2 of 0.89, 0.79 and 0.43 for the three testing satellite data, the latter with $p = 0.14$ can be discarded. The pH is also related with the amount of chlorophyll and tend to increase with the presence of algae and cyanobacteria if other factors do not have a more important influence. Conductivity models are also associated with relatively high r^2 (0.69, 0.76 and 0.69). The conductivity

Sentinel-2/MSI - 30×30 m kernels					
Parameter	r ²	MAE	RMSE	NRMSE	p-value
Chl-a ($\mu\text{g/L}$)	0.71	0.77	0.92	42.0	< 0.01
Secchi (cm)	0.85	40.51	48.52	36.8	< 0.01
Turbidity (NTU)	0.78	0.13	0.16	44.6	< 0.01
pH	0.89	0.03	0.04	30.5	< 0.01
DO (mg/L)	0.85	0.06	0.07	36.2	< 0.01
ORP (mV)	0.65	4.61	6.51	56.3	0.01
Conduct. (mV)	0.69	4.38	5.58	53.0	0.03
TC (mg/L)	0.63	8.23	10.01	57.7	0.06*
OC (mg/L)	0.46	7.46	9.26	70.3	0.04
Sentinel-2/MSI - 90×90 m kernels					
Parameter	r ²	MAE	RMSE	NRMSE	p-value
Chl-a ($\mu\text{g/L}$)	0.75	0.65	0.84	38.6	< 0.01
Secchi (cm)	0.84	39.77	49.48	37.5	< 0.01
Turbidity (NTU)	0.80	0.13	0.16	42.9	< 0.01
pH	0.79	0.05	0.06	43.4	< 0.01
DO (mg/L)	0.83	0.06	0.08	38.6	< 0.01
ORP (mV)	0.62	5.20	6.78	58.6	0.02
Conduct. (mV)	0.76	3.70	4.87	46.1	0.01
TC (mg/L)	0.49	7.87	9.11	68.4	0.19*
OC (mg/L)	0.45	7.50	9.33	70.8	0.04
Landsat-8/OLI - 90×90 m kernels					
Parameter	r ²	MAE	RMSE	NRMSE	p-value
Chl-a ($\mu\text{g/L}$)	0.67	0.84	1.03	47.3	< 0.01
Secchi (cm)	0.81	39.72	54.15	41.1	< 0.01
Turbidity (NTU)	0.80	0.13	0.16	42.7	< 0.01
Temperature (°)	0.03	0.42	0.53	94.3	0.52*
pH	0.43	0.08	0.10	75.1	0.14*
DO (mg/L)	0.69	0.08	0.11	53.1	0.03
ORP (mV)	0.43	6.22	8.32	71.9	0.14
Conduct. (mV)	0.69	4.76	5.59	53.0	0.03
TC (mg/L)	0.62	6.50	7.81	58.7	0.02
OC (mg/L)	0.54	7.50	8.51	64.6	0.01

* models not considered valid using the $p < 0.05$ critical value.

Table 6. Evaluation metrics for all models and for the three image situations considered (MSI-30, MSI-90 and OLI-90)

of water is related with the concentration of ions, specifically dissolved salts from inorganic material. These chemical analysis were not available for this article but TC concentrations could include carbonates. Higher pH values are also related to greater conductivity. These relations are observable in Table 2 and Table 3 and bring an explanation to the strength of these models.

Figure 3 and Figure 4 illustrate the maps that were generated for the chl-a and turbidity models and for both the MSI and OLI sensors.

CONCLUSION

This study aimed at comparing the performance of Sentinel-2's MSI and Landsat-8's OLI sensors for estimating water quality parameters through empirical statistical inference using regression. Both sensors performed very well for creating multiple regression models of three optically active components: chl-a, Secchi disk depth and turbidity. Furthermore, the MSI sensor performed slightly better than the OLI one. For the optically non-active parameters, the MSI sensor had a more evident advantage over the OLI sensor. While the former produced five

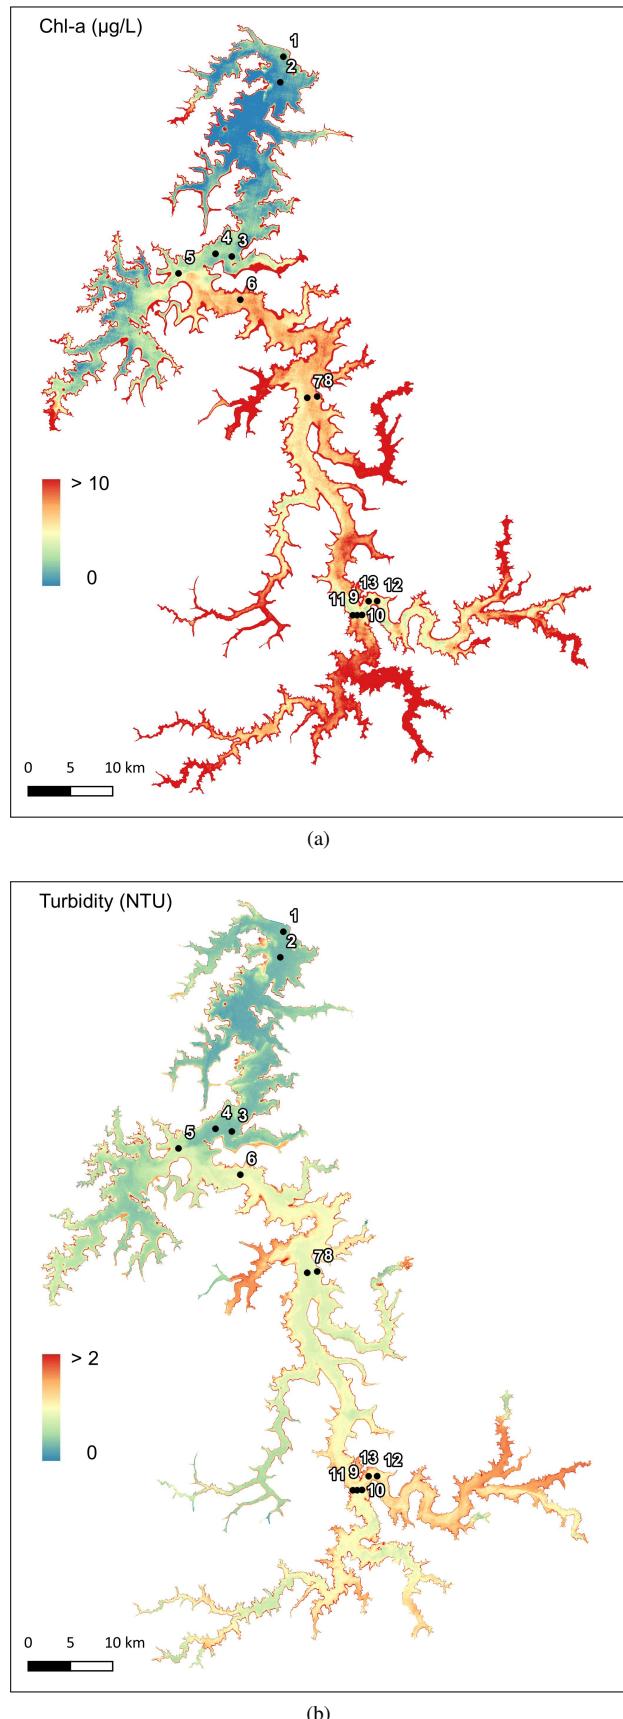


Figure 3. Maps produced using the chlorophyll-a (a) and turbidity (b) models for the Sentinel-2 MSI sensor.

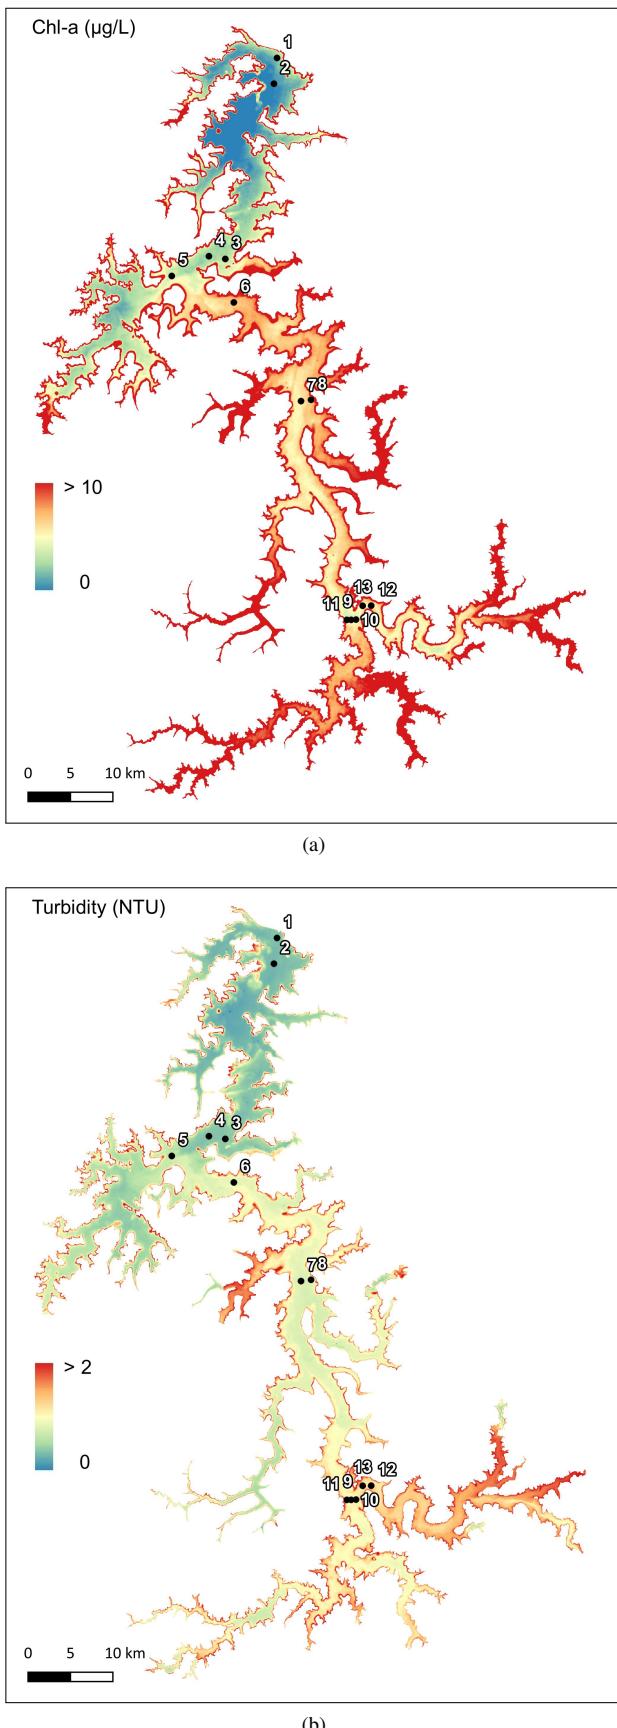


Figure 4. Maps produced using the chlorophyll-a (a) and turbidity (b) models for the Landsat-8 OLI sensor.

models with $r^2 > 0.6$, the latter only three. These parameters have no direct effect on the at-sensor radiance but are the consequence of the optically active parameters recorded. As such these models are not exportable to other locations or even for the same location at different times.

For the MSI sensor, the size of the MSI kernel (30×30 vs 90×90) had little effect on the results; some parameter models were better with the 90 m kernel (chl-a, turbidity, conductivity), some were worse (Secchi depth, pH, DO). These averaging kernels were used instead of single pixel vectors because 1) only an hand-held navigation GNSS with an estimated precision of ≈ 5 m was used and, 2) the boat was not anchored and wind (although very light) and current affected the boat's location during the sampling.

No valid temperature model could be produced using Landsat-8's TIR sensor. Sampling delays were probably the major cause for this poor results but might also be attributed to the calibration problems of the sensor.

We explain the difference between the two sensors based on their differences. Firstly, the MSI has more bands, especially in the visible-near infrared region (three red-edge bands: 700–800 μm). On top of these additional bands, some of the MSI bands have a finer spectral resolution like the green (3), red (4) and near infrared (8a) bands. Finally, the MSI spatial resolutions are of 10 m (4 bands), 20 m (6 bands) and 60 m (3 bands) whereas all the OLI bands have a single spatial resolution of 30 m. Other authors that have compared the performance of statistical models with these two sensors have reached similar conclusions (Yadav et al., 2019, Govedarica, Jakovljević, 2019).

The field campaign lasted about six hours which probably caused problems for the surface temperature that responds very quickly to the sun elevation. Although the remaining parameters are considered more stable, they are still affected by the changing conditions of temperature and illumination. This means that conducting faster sampling near the image acquisition time could potentially improve these models as well. Future campaigns will try to reduce these effects by using two teams instead of one.

ACKNOWLEDGEMENTS

This work was produced within the frame of a wider project entitled “Intelligent Water Quality Monitoring through the Development of Photo-optical Algorithm” and financed by the Companhia Energética de Minas Gerais (CEMIG, project GT-0607). The authors are most grateful to the GT-0607 Team who made this article possible.

REFERENCES

- Babyak, M., 2004. What you see may not be what you get: a brief, nontechnical introduction to overfitting in regression-type models. *Psychosomatic medicine*, 66(3), 411–421.
- Barbosa, C., Novo, E., Martins, V., 2019. *Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações*. Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

- Cachapuz, P., 2006. *Usinas da CEMIG: a história da eletricidade em Minas e no Brasil, 1952–2005*. Centro da Memória da Eletricidade no Brasil, Rio de Janeiro.
- Dutra, V., Tavares, P., Ribeiro, H., 2019. Analysis of cloud condition on Sentinel-2 MSI and Landsat-8 OLI images of a public supply lake in Belém-Pará-Brazil. *Ambiente e Água-An Interdisciplinary Journal of Applied Science*, 14(4), 1–11.
- Giardino, C., Bresciani, M., Villa, P., Martinelli, A., 2010. Application of remote sensing in water resource management: the case study of Lake Trasimeno, Italy. *Water resources management*, 24(14), 3885–3899.
- González-Márquez, L., Torres-Bejarano, F., Torregroza-Espinosa, A., Hansen-Rodríguez, I., Rodríguez-Gallegos, H., 2018. Use of Landsat-8 images for depth and water quality assessment of El Guajaro reservoir, Colombia. *Journal of South American Earth Sciences*, 82, 231–238.
- Govedarica, M., Jakovljević, G., 2019. Monitoring spatial and temporal variation of water quality parameters using time series of open multispectral data. *International Conference on Remote Sensing and Geoinformation of the Environment*, 11174, 1–11.
- James, G., Witten, D., Hastie, T., Tibshirani, R., 2013. *An introduction to statistical learning*. Springer Science, New York.
- Karaoui, I., Arioua, A., Boudhar, A., Hssaisoune, M., El Mouattassime, S., Ouhamchich, K., Elhamdouni, D., Idrissi, A., Nouaim, W., 2019. Evaluating the potential of Sentinel-2 satellite images for water quality characterization of artificial reservoirs: The Bin El Ouidane Reservoir case study (Morocco). *Meteorology Hydrology and Water Management. Research and Operational Applications*, 7(1), 31–39.
- Landsat-USGS, 2018. Surface Reflectance Code (LASRC) Product Guide. *USGS and NASA: Reston, VA, USA*.
- Liu, L., Wang, Y., 2019. Modelling reservoir turbidity using Landsat-8 satellite imagery by gene expression programming. *Water*, 11(7), 1479.
- Lonjou, V., Desjardins, C., Hagolle, O., Petrucci, B., Tremas, T., Dejus, M., Makarau, A., Auer, S., 2016. Maccs-atcor joint algorithm (maja). *Remote Sensing of Clouds and the Atmosphere XXI*, 10001, International Society for Optics and Photonics, 1–13.
- Mainali, J., Chang, H., Chun, Y., 2019. A review of spatial statistical approaches to modeling water quality. *Progress in Physical Geography: Earth and Environment*, 43(6), 841–826.
- Matthews, M., 2011. A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. *International Journal of Remote Sensing*, 32(21), 6855–6899.
- Mertes, L., Dekker, A., Brakenridge, G., Birkett, C., Letournou, G., 2004. *Manual of Remote Sensing, vol. 4: Remote Sensing for Natural Management and Environmental Monitoring*. 4, John Wiley and Sons, Hoboken, NJ, USA, chapter Rivers and lakes, 345–400.
- Mishra, D., Ogashawara, I., Gitelson, A., 2017. *Bio-optical modeling and remote sensing of inland waters*. Candice Janco.
- Montanaro, M., Gerace, A., Lunsford, A., Reuter, D., 2014. Stray light artifacts in imagery from the Landsat 8 Thermal Infrared Sensor. *Remote Sensing*, 6(11), 10435–10456.
- Moore, D., 1998. Ambient water quality criteria for organic carbon in British Columbia. Report: Approved Water Quality Guidelines, Province of British Columbia, Ministry of Environment, Lands and Parks, Victoria, BC.
- Mushtaq, F., Nee Lala, M., 2017. Remote estimation of water quality parameters of Himalayan lake (Kashmir) using Landsat 8 OLI imagery. *Geocarto international*, 32(3), 274–285.
- Potes, M., Rodrigues, G., Penha, A., Novais, M., Costa, M., Salgado, R., Morais, M., 2018. Use of Sentinel 2-MSI for water quality monitoring at Alqueva reservoir, Portugal. *Proceedings of the International Association of Hydrological Sciences*, 380, 73–79.
- Teodoro, A., 2016. Optical satellite remote sensing of the coastal zone environment—An overview. *Environment Applications of Remote Sensing*, 1, 165–196.
- USGS, 2019. Landsat 8 (L8) Data Users Handbook. Document Number LSDS-1574, Version 5.0, Department of the Interior U.S. Geological Survey, Sioux Falls, SD, USA.
- von Sperling, E., 1999. *Morfologia de lagos e represas*. DESA/UFMG, Belo Horizonte.
- Watanabe, F., Alcantara, E., Rodrigues, T., Rotta, L., Bernardo, N., Imai, N., 2018. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita reservoir, Brazil). *Anais da Academia Brasileira de Ciências*, 90(2), 1987–2000.
- Yadav, S., Yamashiki, Y., Susaki, J., Yamashita, Y., Ishikawa, K., 2019. Chlorophyll estimation of lake water and coastal water using Landsat-8 and Sentinel-2A Satellite. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(3/W7), 77–82.
- Yepes, S., Laraque, A., Martinez, J., De Sa, J., Carrera, J., Castellanos, B., Gallay, M., Lopez, J., 2018. Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River (Venezuela). *Comptes Rendus Geoscience*, 350(1-2), 20–30.

ANEXO B – Artigo: Estimativa da qualidade da água do Reservatório de Três Marias a partir dos sensores Sentinel-2 MSI e Landsat-8 OLI

PIZANI, F.M.C.; MAILLARD, P.; FERREIRA, A.F.F.; AMORIM, C.C.. Estimativa da qualidade da água do Reservatório de Três Marias a partir dos sensores Sentinel-2 MSI e Landsat-8 OLI. In: Simpósio da Bacia Hidrográfica do Rio São Francisco, 2020, Belo Horizonte. III Simpósio da Bacia Hidrográfica do Rio São Francisco, 2020.

A Importância da Ciência para o Futuro do Rio São Francisco

ESTIMATIVA DA QUALIDADE DA ÁGUA DO RESERVATÓRIO DE TRÊS MARIAS A PARTIR DOS SENsoRES SENTINEL-2 MSI E LANDSAT-8 OLI

Pizani, F. M. C.¹; Maillard, P.¹; Ferreira, A. F. F.²; Amorim, C. C.²

¹ Universidade Federal de Minas Gerais – UFMG/IGC
Campus Pampulha, Belo Horizonte/MG, CEP 31270.901
fm.coelho@yahoo.com.br – philippermaillard@yahoo.com.br

² Universidade Federal de Minas Gerais – UFMG/DESA
Campus Pampulha, Belo Horizonte/MG, CEP 31270.901
adrielly.fonseca@gmail.com – camila@desa.ufmg.br

Abstract. The low operational cost of using freely available remote sensing data is a strong incentive for water agencies to complement their field campaigns and produce spatially distributed maps of some water quality parameters. The objective of this study is to compare the performance of Sentinel-2 MSI and Landsat-8 OLI sensors to produce multiple regression models of water quality parameters in the Três Marias hydroelectric reservoir. Water quality parameters were measured in loco using sensors and also analyzed in laboratory from water samples collected simultaneously. The date of sampling corresponded to the almost simultaneous overflight of Sentinel-2B and Landsat-8 satellites. Two optically active parameters were considered in this study case: chlorophyll-a (chl-a) and turbidity. The multiple regression models used the spectral reflectance bands from both sensors (separately) as predictors. The reflectance values were based on an averaging window of 90x90 m instead of single pixel vectors. Stepwise variable selection combined with a priori knowledge were used to optimized the choice of predictors. The optically active parameters yielded strong regression models and significant results with both the Sentinel and Landsat sensors. All results with $r^2 > 0.75$ and p-value < 0.01. The spectral bands resulting from the selection methods were good predictors.

Palavras-Chave – Qualidade da água; Sensoriamento remoto; Modelos estatísticos; Análise de regressão; Reflectância.

INTRODUÇÃO

Aplicações de técnicas de sensoriamento remoto e de processamento de imagens em ambientes aquáticos são possíveis devido à relação entre o comportamento espectral e os componentes opticamente ativos (COAs) da água, que respondem de forma diferente quando comparados aos constituintes terrestres. Assim, a reflectância e absorção dos COAs da água podem ser estudados em determinados comprimentos de onda. A água contém uma assinatura espectral única que pode ser distinguida pela alta absorção na faixa do infravermelho próximo, o que faz com que os corpos d'água possam ser detectados e delimitados facilmente (Teodoro, 2016, p.167). As alterações observadas nas propriedades ópticas da água vêm dos efeitos da interação com a radiação solar que permite que os COAs sejam usados como indicadores de qualidade da água (Barbosa *et al.*, 2019, p.25).

Atualmente, o monitoramento dos parâmetros de qualidade da água demanda custos altos de coletas e de análise das amostras (Karaoui *et al.*, 2019, p.34; Yepez *et al.*, 2018, p.21), além dos custos referentes ao tempo despendido e à mão-de-obra especializada Giardino *et al.*, 2010, p.3887). O monitoramento a distância promove a diminuição destes custos e possibilita a estimativa de alguns parâmetros de qualidade da água com alta frequência temporal e de forma distribuída espacialmente. Diversos satélites apresentam aquisição sistemática de imagens com resoluções variadas da ordem dos centímetros a quilômetros. Dentre os satélites ópticos mais comuns estão as

A Importância da Ciência para o Futuro do Rio São Francisco

séries Landsat (como o Landsat-8, portando o sensor OLI) e Sentinel (como o Sentinel-2, A e B, portador do sensor MSI) que fornecem imagens com frequência temporal variando de 16 dias (Landsat) a 5 dias (Sentinel). As missões Landsat-8 e Sentinel-2 fornecem gratuitamente imagens com alta resolução espacial além de facilidade de aquisição dos dados.

Em paralelo ao uso de sensores remotos, a modelagem espacial associada à estatística torna-se uma ferramenta capaz de gerar modelos distribuídos de parâmetros bio-ópticos de qualidade da água. As abordagens que utilizam métodos estatísticos são comuns em estudos de diagnósticos de qualidade da água, sobretudo, aquelas que utilizam técnicas de regressão, que estão entre as mais frequentemente aplicadas (Mainali *et al.*, 2019, p.802).

Os grandes reservatórios brasileiros demandam monitoramento extensivo de um elevado número de parâmetros ambientais, uma vez que muitos deles fornecem subsídio à população que deles se beneficia, seja pelo lazer ou pela economia, como é o caso do Reservatório de Três Marias na bacia do Rio São Francisco. Atualmente, os monitoramentos são realizados de forma tradicional e *in situ*. Este fato ocasiona a alocação significativa de recursos humanos e financeiros, o que dificulta as ações de preservação e de controle ambiental em tempo satisfatório. Outros fatores também podem ser limitantes neste monitoramento como a dificuldade de se obter dados tendo em vista as particularidades e a dimensão do corpo hídrico (Karaoui *et al.*, 2019, p.31).

Este estudo buscou avaliar e comparar o desempenho dos sensores a bordo dos satélites Landsat-8 e Sentinel-2 para estimar parâmetros de COA. Foram realizadas análises de regressão, de maneira a correlacionar parâmetros de qualidade da água coletados *in situ* com valores de reflectância e gerar modelos distribuídos de toda área da represa.

METODOLOGIA

Área de Estudo e Aquisição de Dados Limnológicos

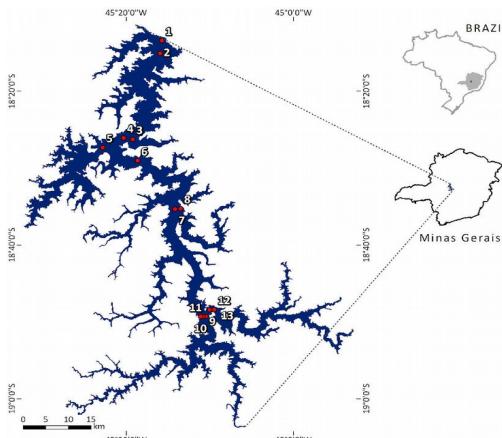
O Reservatório de Três Marias está localizado no contexto hidrográfico da Bacia do Alto Rio São Francisco (Figura 1). O reservatório apresenta área útil de inundação de 1090 km² e cerca de 20 Gm³ de volume máximo. O reservatório se insere entre os dez maiores reservatórios brasileiros quanto à área e ao volume (von Sperling, 1999, p.117–119). A região de inserção do reservatório se caracteriza por duas estações climáticas bem definidas, sendo uma chuvosa durante o período do verão e outra seca, no período do inverno.

A coleta de dados *in situ* ocorreu no dia 4 de outubro de 2019 durante o período da manhã e utilizou um barco a motor que percorreu 85 km entre a barragem e a confluência dos rios Paraopeba e São Francisco. A data foi escolhida de forma a sincronizar a coleta com a passagem dos satélites Landsat-8 e Sentinel-2, que coincidem a cada 80 dias. As condições climáticas previstas foi outro fator que motivou para a escolha da data, uma vez que havia indicativo de céu claro e limpo.

Foram levantados 13 pontos amostrais ao longo do reservatório. Mediú-se *in loco* o parâmetro turbidez com o apoio de um turbidímetro enquanto o parâmetro clorofila-a (chl-a) foi determinado em laboratório com amostras. Outros parâmetros não ópticamente ativos também foram mensurados mas, não serão considerados para efeitos deste estudo. Apenas os parâmetros chl-a e turbidez foram considerados, ambos passíveis de monitoramento por sensoriamento remoto.

A Importância da Ciência para o Futuro do Rio São Francisco

FIGURA 1. Localização dos pontos de coleta de amostras no Reservatório de Três Marias.



Aquisição de Dados de Sensoriamento Remoto e Pré-processamento

Este trabalho utilizou os produtos gratuitos de nível 2A provenientes dos satélites Sentinel-2 (Agência Espacial Europeia - ESA) e Landsat-8 (Serviço Geológico dos Estados Unidos - USGS). Imagens de nível 2A são processadas e tem corrigidas a radiometria e geometria, dispondo de produtos reflectância, reparados de acordo com parâmetros próprios. A passagem do Sentinel-2 ocorreu às 10:12:49 AM e do Landsat-8 às 10:03 AM (horário local). Ambas imagens apresentaram excelente condição climática e ausência total de nuvens. Os dados foram convertidos de radiância para reflectância na superfície. As bandas de 20 m do satélite Sentinel-2 e a banda 1, de 60 m de resolução espacial, foram reamostradas para 10 m pelo método bilinear. As bandas do satélite Landsat-8 foram mantidas na resolução espacial de 30 m.

Os pixels de reflectância dos pontos amostrados foram extraídos em janelas de 90x90 m em torno da coordenada dos pontos para ambas as imagens. Isto permitiu desconsiderar o erro inerente ao GNSS portátil utilizado e pela deriva natural do barco causada pela ação dos ventos. As estatísticas de cada janela foram computadas sobre as imagens e a média do valor espectral foi utilizado como valor de referência para a análise.

Modelos Estatísticos e Análise de Regressão

O software estatístico RStudio (v. 1.5.5019) foi utilizado para as análises de regressão lineares múltiplas a fim de correlacionar os valores dos parâmetros coletados *in situ* e as médias espetrais das bandas de cada imagem. Técnicas de regressão estatística podem fornecer resultados robustos quando aplicados à áreas de estudo específicas (Matthews, 2011, p.6872).

Foram aplicadas regressões lineares múltiplas aos dois parâmetros considerando todas as bandas disponíveis estipuladas. Dois métodos de seleção de variáveis foram utilizados:

- *Stepwise*: consiste na seleção do melhor conjunto de preditores por iteração, de forma a indicar as variáveis que apresentam o melhor desempenho para o modelo (James *et al.*, 2013, p.207). O método adotado utilizou a abordagem híbrida ou bidirecional que considera

A Importância da Ciência para o Futuro do Rio São Francisco

a adição de variáveis uma a uma (forward) e, ao final, remove aquelas que não são importantes para o modelo (backward);

- Referência bibliográfica: o segundo método combinou preditores amplamente utilizados, com base em levantamento bibliográfico de estudos de sensoriamento remoto aplicados à chl-a e turbidez. Esta escolha objetivou refinar os resultados gerados pela regressão *Stepwise* garantindo a presença de importantes bandas na análise (Babyak, 2004, p.419).

A opção por estratégias combinadas teve por finalidade reduzir o número de variáveis preditoras, tornando o modelo mais objetivo, mais significativo e evitando um possível *overfitting*.

Validação dos Modelos e Avaliação da Acurácia

Foram aplicadas métricas estatísticas com a finalidade de descrever a diferença entre os dados previstos e coletados, além de avaliar a performance dos modelos. As métricas foram: Coeficiente de Determinação (r^2), Erro Médio Absoluto (MAE), Raiz do Erro Médio Quadrático (RMSE) e Raiz do Erro Médio Quadrático Normalizado (NRMSE). Após a aplicação das métricas estatísticas, os modelos de regressão foram aplicados às bandas dos satélites correspondentes por meio de álgebra de mapas para gerar mapas de chl-a e de turbidez.

RESULTADOS E DISCUSSÃO

Qualidade da Água no Reservatório de Três Marias

Os resultados obtidos em laboratório coletados durante a campanha de campo no Reservatório de Três Marias estão apresentados na Tabela 1. Analisando os dados obtidos nos pontos amostrais de uma maneira geral, o que se percebe claramente é uma certa (ainda que pequena) deteriorização da qualidade da água no reservatório a medida em que se avança no sentido norte-sul. Particularmente, nos pontos próximos aos braços dos principais afluentes (Rio São Francisco e Rio Paraopebas) há os maiores índices de turbidez se comparados aos demais pontos da represa. Os dois primeiros pontos, localizados próximo à barragem no vetor norte do reservatório, apresentam os melhores resultados para o parâmetro relativo à transparência, indicando turbidez extremamente baixa (0,2 NTU).

Os pontos 3, 4, 5 e 6 estão inseridos na porção centro-norte do reservatório próximo a áreas caracterizadas por atividades agrícolas e piscicultura, com forte presença de pivôs centrais e tanques de pesca. Entre estes pontos estão os maiores índices de chl-a (8,10 µg/L). Para o Instituto de Gestão das Águas do Estado de Minas Gerais (IGAM), considerando apenas a chl-a identificada na data da coleta, estes valores não indicam, neste momento, estado de eutrofização do reservatório. Entretanto, cabe ressaltar que esta classificação não é simplória e ainda depende de uma série de fatores que não serão destrinchados nesta pesquisa. É igualmente importante considerar o período seco em que a coleta foi realizada, onde a qualidade da água é habitualmente mais alta.

Os pontos 7 e 8 localizam-se na extremidade norte de uma pequena ilha, denominada Ilha do Mangabal, e apresentam altos índices de turbidez e chl-a, em comparação aos demais. Próximo a estes pontos, foram observadas possíveis colônias de algas e cianobactérias. Este fato reafirma a necessidade do monitoramento contínuo, especialmente para parâmetros como chl-a, fósforo e

A Importância da Ciência para o Futuro do Rio São Francisco

nitrogênio (carga de nutrientes), que podem contribuir para uma futura eutrofização do reservatório além de alteração do ecossistema local de modo significativo (Barbosa *et al.*, 2019, p.49).

TABELA 1. Mensuração dos parâmetros opticamente ativos coletados *in situ*.

PONTO	CHL-a ($\mu\text{g/L}$)	TURBIDEZ (NTU)
1	1.94	0.24
2	1.78	0.20
3	2.08	0.65
4	2.15	0.32
5	1.63	0.53
6	8.10	1.06
7	5.68	0.53
8	7.76	1.11
9	4.40	1.04
10	4.38	1.10
11	5.35	1.08
12	4.30	1.08
13	3.82	1.11

Os pontos de 9 a 13 estão localizados na bifurcação entre os rios São Francisco (pontos 9, 10 e 11) e Paraopebas (12 e 13) e representam um conjunto de valores que indicam menor qualidade da água para o reservatório. Além da baixa transparência, observam-se os maiores índices de turbidez presentes no reservatório (variando entre 1,04 e 1,11 NTU).

Análise de regressão e avaliação da acurácia

A construção de modelos relacionando reflectância espectral da água e a sua qualidade no Reservatório de Três Marias foi derivada, primeiramente, pelo método *Stepwise*. O método consiste na seleção das variáveis independentes mais impactantes para explicar a variância de cada parâmetro. A combinação entre o método *Stepwise* e seleção a priori de preditores baseado em bibliografias publicadas levou em consideração as aplicações recentes para chl-a (Yadav *et al.*, 2019; Dutra *et al.*, 2019; Watanabe *et al.*, 2018) e turbidez (Liu e Wang, 2019; Gonzalez-Marquez *et al.*, 2018). Os resultados obtidos estão apresentados na Tabela 2.

TABELA 2. Seleção das bandas espectrais e método utilizado.

PARÂMETRO	SENTINEL-2/MSI	LANDSAT-8/OLI	MÉTODO
Chl-a	B2, B3, B4, B5	B2, B3, B4	<i>Stepwise</i> + Referência
Turbidez	B1, B3	B1, B3	<i>Stepwise</i> + Referência

A partir da seleção de bandas, os modelos puderam ser desenvolvidos por meio de regressão linear múltipla. A Tabela 3 descreve as equações de regressão para estimar cada parâmetro de qualidade da água a partir dos valores de reflectância selecionados para cada modelo.

A Importância da Ciência para o Futuro do Rio São Francisco

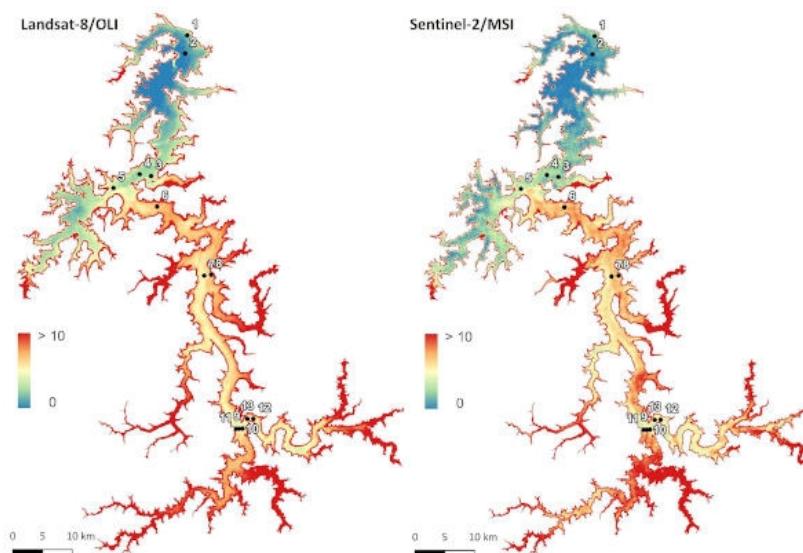
TABELA 3. Equações de regressão dos modelos de qualidade da água.

DEPENDENTE	Equações SENTINEL-2/MSI	r^2
Chl-a	$18.420 + (-1263.615 * B2) + (413.934 * B3) + (52.127 * B4) + (710.274 * B5)$	0.75
Turbidez	$0.4532 + (-56.94 * B1) + (43.57 * B3)$	0.80
DEPENDENTE	Equações LANDSAT-8/OLI	r^2
Chl-a	$15.717 + (-1247.530 * B2) + (192.236 * B3) + (846.290 * B4)$	0.67
Turbidez	$0.23 + (-59.28 * B1) + (48.00 * B3)$	0.80

A estatística descritiva apresentada revela altos índices referentes ao r^2 para os parâmetros opticamente ativos avaliados, variando entre 0.67 e 0.80 para ambas as janelas. Isto significa que as bandas espectrais definidas por meio dos métodos propostos demonstraram ser bons preditores dos parâmetros utilizados, em especial para a janela 90x90 m do sensor MSI.

Entretanto, é necessário considerar, além dos índices apontados pelos coeficientes adotados nesta pesquisa, o quanto os modelos são estatisticamente significantes e os erros associados aos modelos ajustados. Primeiramente, para a validação dos modelos, foi considerada a observação do p-value < 0.05, ainda que a aplicação do método *Stepwise* permita um valor mais liberal para este índice (Babyak, 2004, p.416). Ainda assim, todos os modelos apresentaram valores abaixo de 0.01. Ao analisar os modelos da janela de 90x90 m do sensor OLI, percebe-se que os ajustes tiveram desempenho levemente inferior àqueles referentes aos modelos do sensor MSI. As Figuras 2 e 3 apresentam os mapas gerados para os modelos de chl-a e turbidez para os sensores OLI e MSI. As métricas utilizadas para a avaliação dos modelos podem ser observadas na Tabela 4.

FIGURA 2. Mapa dos modelos de chl-a para os sensores OLI e MSI, respectivamente.



A Importância da Ciência para o Futuro do Rio São Francisco

FIGURA 3. Mapa dos modelos de turbidez para os sensores OLI e MSI, respectivamente.

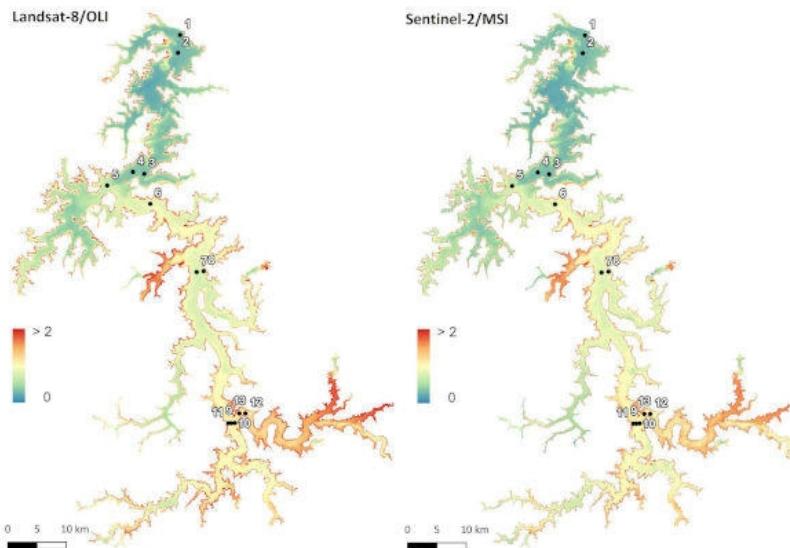


TABELA 4. Validação dos modelos com as métricas estabelecidas para os sensores MSI e OLI.

PARÂMETRO	SENTINEL-2/MSI					LANDSAT-8/OLI				
	r²	MAE	RMSE	NRMSE	p	r²	MAE	RMSE	NRMSE	p
Chl-a	0.75	0.65	0.84	38.6	<0.01	0.67	0.84	1.03	47.3	<0.01
Turbidez	0.80	0.13	0.16	42.9	<0.01	0.80	0.13	0.16	42.7	<0.01

CONCLUSÕES

O estudo comparou o desempenho dos sensores OLI e MSI quando aplicados à qualidade da água. Conclui-se que tanto o Landsat-8 quanto o Sentinel-2 são capazes de predizer parâmetros de qualidade da água (chl-a e turbidez) com altos índices de confiabilidade. Os pontos seguintes sintetizam as conclusões do estudo:

- O sensor MSI (Sentinel-2) foi superior ao OLI (Landsat-8) para produzir modelos de chl-a e turbidez;
- A resolução espacial mais fina pode ter contribuído em parte para a melhor performance do sensor MSI. Esta conclusão é apoiada por outros autores com estudos semelhantes (Yadav *et al.*, 2019; Govedarica *et al.*, 2019);
- A resolução espectral mais refinada do MSI também contribui para explicar o resultado, bem como o maior número de bandas (*red-edge*) do sensor;
- Ainda assim, ambos os sensores permitiram produzir resultados muito bons com $r^2 \geq 0.75$ para o MSI e $r^2 \geq 0.67$ para o OLI.

Os resultados preliminares aqui alcançados encorajam a continuidade de novos estudos na área pesquisada a fim de aperfeiçoar a precisão dos valores obtidos por meio de análise estatística.

A Importância da Ciência para o Futuro do Rio São Francisco

REFERÊNCIAS

- BABYAK, M. A. What you see may not be what you get: a brief, nontechnical introduction to overfitting in regression-type models. **Psychosomatic Medicine**, v.66, n.3, p.411–421, 2004.
- BARBOSA, C. C. F., NOVO, E. M. L. M., MARTINS, V. S. **Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2019, 178p.
- DUTRA, V. A. B., TAVARES, P. A., RIBEIRO, H. M. C. Analysis of cloud condition on Sentinel-2 MSI and Landsat-8 OLI images of a public supply lake in Belém-Pará-Brazil. **Ambiente e Água-An Interdisciplinary Journal of Applied Science**, v.14, n.4, p.1–11, 2019.
- GIARDINO, C., BRESCIANI, M., VILLA, P., MARTINELLI, A. Application of remote sensing in water resource management: the case study of Lake Transimeno, Italy. **Water Resour Manage**, v.24, p.3885–3899, 2010.
- GONZÁLEZ-MÁRQUEZ, L. C., TORRES-BEJARANO, F. M., TORREGROZA-ESPINOSA, A. C., HANSEN-RODRIGUEZ, I. R., RODRIGUEZ-GALLEGOS, H. B. Use of Landsat-8 images for depth and water quality assessment of El Guajaro reservoir, Colombia. **Journal of South American Earth Sciences**, v.82, p.231–238, 2018.
- GOVEDARICA, M., JAKOVLJEVIĆ, G. Monitoring spatial and temporal variation of water quality parameters using time series of open multispectral data. **International Conference on Remote Sensing and Geoinformation of the Environment**, v.11174, p.1–11, 2019.
- JAMES, G., WITTEN, D., HASTIE, T., TIBSHIRANI, R. **An introduction to statistical learning**. New York: Springer Science, 2013. 441p.
- KARAOUI, I., ARIOUA, A., BOUDHAR, A., HSSAISOUNE, M., EL MOUATASSIME, S., OUHAMCHICH, K. A., ELHAMDOUNI, D., IDRISI, A. A., NOUAIM, W. Evaluating the potential of Sentinel-2 satellite images for water quality characterization of artificial reservoirs: The Bin El Ouidane Reservoir case study (Morocco). **Meteorology Hydrology and Water Management: Research and Operational Applications**, v.7, n.1, p.31–39, 2019.
- LIU, L., WANG, Y. Modelling Reservoir Turbidity Using Landsat 8 Satellite Imagery by Gene Expression Programming. **Water**, v.11, n.7, p.1479, 2019.
- MAINALI, J., CHANG, H., CHUN, Y. A review of spatial statistical approaches to modeling water quality. **Progress in Physical Geography: Earth and Environment**, v.43, n.6, p.826–841, 2019.
- MATTHEWS, M. W. A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. **International Journal of Remote Sensing**, v.32, n.21, p.6855–6899, 2011.
- TEODORO, A. C. Optical satellite remote sensing of the coastal zone environment: an overview. **Environment Applications of Remote Sensing**, v.1, p.165–196, 2016.
- VON SPERLING, E. **Morfologia de lagos e represas**. Belo Horizonte: DESA/UFMG, 1999. 137p.
- WATANABE, F., ALCANTARA, E., RODRIGUES, T., ROTTA, L., BERNARDO, N., IMAI, N. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita reservoir, Brazil). **Anais Da Academia Brasileira de Ciências**, v.90, n.2, p.1987–2000, 2018.
- YADAV, S., YAMASHIKI, Y., SUSAKI, J., YAMASHITA, Y., ISHIKAWA, K. Chlorophyll Estimation of Lake Water and Coastal Water Using Landsat-8 and Sentinel-2A Satellite. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.42, n.3/W7, p.77–82, 2019.
- YEPEZ, S., LARAQUE, A., MARTINEZ, J., DE SA, J., CARRERA, J. M., CASTELLANOS, B., GALLAY, M., LOPEZ, J. Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River (Venezuela). **Comptes Rendus Geoscience**, v.350, n.1–2, p.20–30, 2018.

ANEXO C – Artigo: Modelagem empírica de componentes opticamente ativos por técnicas de sensoriamento remoto no Reservatório de Três Marias/MG

PIZANI, F.M.C.; MAILLARD, P.. Modelagem empírica de componentes opticamente ativos por técnicas de sensoriamento remoto no Reservatório de Três Marias. In: Simpósio Brasileiro de Recursos Hídricos, 2021, Belo Horizonte. XXIV Simpósio Brasileiro de Recursos Hídricos, 2021. p. 1-10.

XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

MODELAGEM EMPÍRICA DE COMPONENTES OPTICAMENTE ATIVOS POR TÉCNICAS DE SENSORIAMENTO REMOTO NO RESERVATÓRIO DE TRÊS MARIAS/MG

Fernanda Mara Coelho Pizani¹; Philippe Maillard²

RESUMO – O Reservatório de Três Marias se caracteriza como um importante ambiente aquático em função dos seus múltiplos usos. Monitorar a qualidade da água deste ambiente é essencial para seu gerenciamento e controle ambiental. O sensoriamento remoto é frequentemente utilizado para estimar os parâmetros opticamente ativos de qualidade das águas de superfície. Este trabalho tem o objetivo de apresentar os resultados do monitoramento de três campanhas de coleta dos componentes clorofila-a, transparência e turbidez coincidentes com a passagem do satélite Sentinel-2. Modelos empíricos de regressão múltipla foram gerados apresentando valores de r^2 entre 0,41 e 0,63 e aplicados às imagens do Sentinel-2. O instrumento MSI com alta resolução espacial, temporal (5 dias) e espectral com bandas não disponíveis no Landsat demonstrou um potencial superior a outros satélites da mesma categoria.

Palavras-Chave – Qualidade da água; Parâmetros opticamente ativos; Sensoriamento remoto

1. INTRODUÇÃO

Águas continentais são consideradas fonte de recursos, onde cerca de 40% da produção agrícola mundial é dependente da irrigação, os processos naturais dependem dos ecossistemas aquáticos, que podem ser muito frágeis, e mais de um bilhão de pessoas no mundo não tem acesso à água potável (Blanchon, 2009). A técnica de represamento é utilizada de forma a satisfazer objetivos como a geração de energia elétrica, lazer, irrigação, piscicultura, navegação, abastecimento humano e industrial, regularização de água e turismo. Estes múltiplos usos se traduzem como importantes benefícios que atendem às necessidades de vários grupos e atores.

Em função dos diversos usos, preservar a qualidade da água dos reservatórios representa um desafio de gestão e de monitoramento. A poluição dos corpos hídricos acarreta a degradação da qualidade da água e provoca sua deterioração. Uma forma eficiente de controle da qualidade da água demanda o monitoramento frequente de parâmetros indicadores da sua condição.

O sensoriamento remoto tem sido utilizado para o monitoramento de recursos hídricos por meio de modelagem e pela estimativa dos parâmetros bio-ópticos. A principal vantagem da sua aplicação é a capacidade de realizá-los de maneira remota e sinótica em grandes áreas que possibilita desenvolver novas técnicas ou ajustar os modelos já existentes (Mishra *et al.*, 2017).

O Reservatório de Três Marias, localizado na região Central de Minas Gerais, apresenta águas geralmente claras, mas seu estado envolve variações notáveis ao longo do ano, o que torna necessária a compreensão sobre sua dinâmica espaço-temporal (Curtarelli *et al.*, 2020). E para compreender esta

1 Universidade Federal de Minas Gerais. Av. Pres. Antônio Carlos, 6627 – Pampulha, Belo Horizonte – MG, 31270-901, (31) 3409-5000, fm.coelho@yahoo.com.br

2 Universidade Federal de Minas Gerais. Av. Pres. Antônio Carlos, 6627 – Pampulha, Belo Horizonte – MG, 31270-901, (31) 3409-5000, philippermaillard@yahoo.com.br

dinâmica, alguns parâmetros como matéria orgânica colorida dissolvida, sedimentos em suspensão e pigmentos fitoplanctônicos podem ser estudados via sensoriamento remoto contribuindo para superar as limitações físicas dos métodos tradicionais (Pinto *et al.*, 2014).

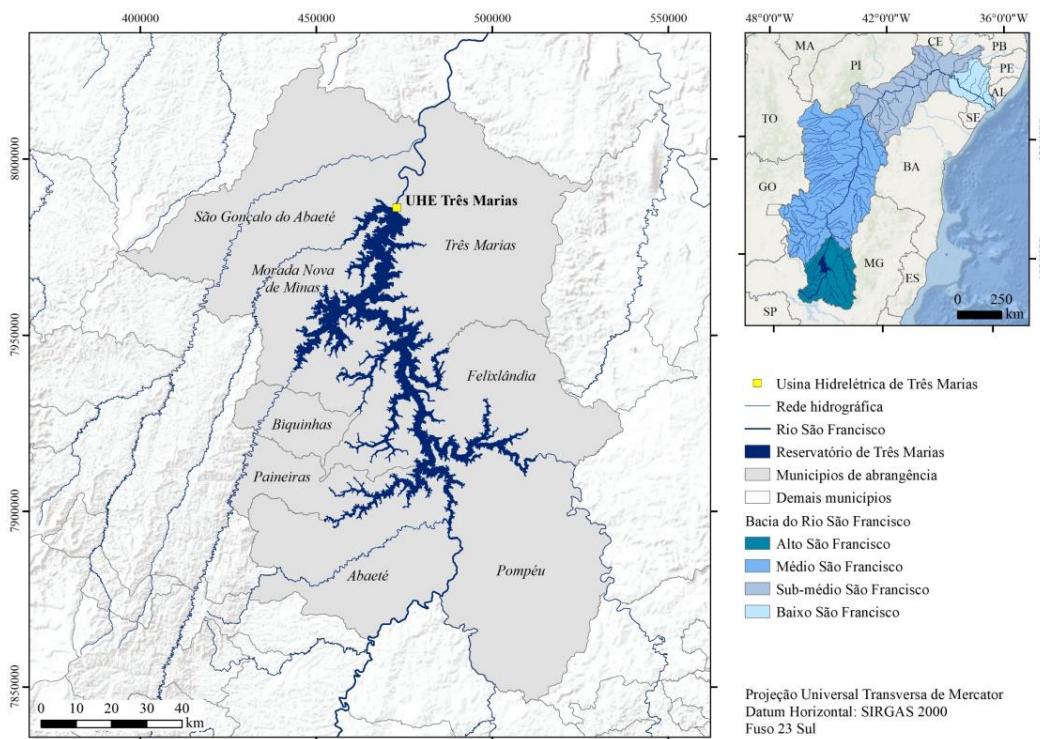
Neste contexto, este estudo apresenta os resultados do monitoramento de três importantes componentes opticamente ativos, clorofila-a (chl-a), turbidez e transparência, por meio de modelagem empírica no Reservatório de Três Marias com base em dados coletados *in situ* e imagens de sensoriamento remoto. Pretende-se ainda avaliar os dados do sensor MSI a bordo do satélite Sentinel-2 como base de construção de modelos de regressão múltipla.

2. METODOLOGIA

2.1. Área de estudo

O Reservatório de Três Marias está localizado na bacia hidrográfica do Rio São Francisco, inserido na sub-bacia do Alto São Francisco, região Central do Estado de Minas Gerais (Figura 1). Está situado entre os paralelos 18°10' e 19°00' de latitude Sul e entre os meridianos 44°50' e 45°35' de longitude Oeste. O barramento do reservatório encontra-se a jusante do Rio São Francisco, onde se localiza a Usina Hidrelétrica de Três Marias sob a concessão da Companhia Energética de Minas Gerais (CEMIG).

Figura 1 – Localização da área de estudo

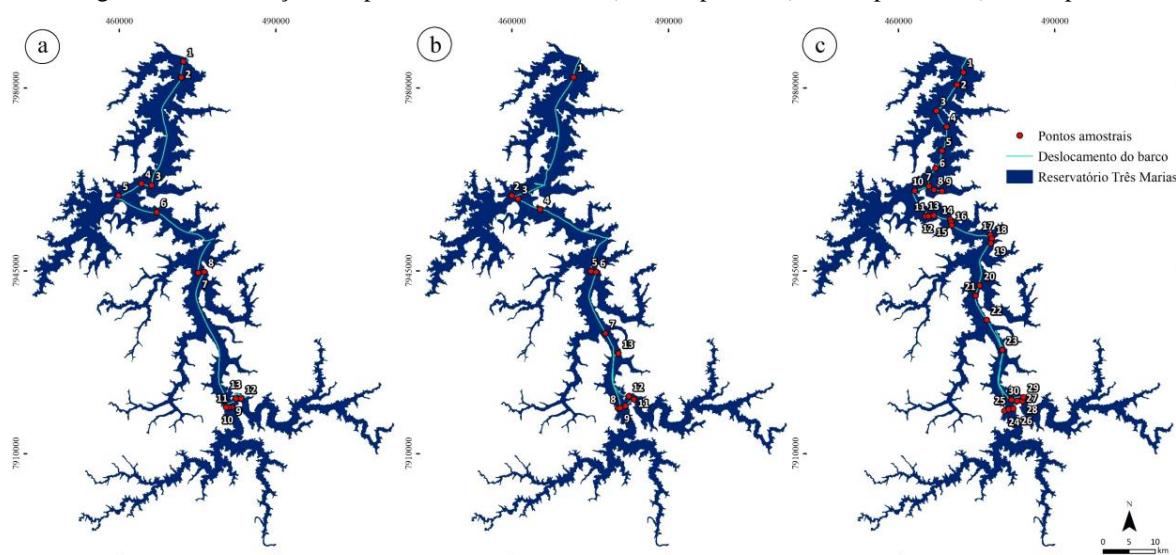


O reservatório apresenta, aproximadamente, 1090 km² de área e se caracteriza pela forma altamente dendrítica. Tem ambiente considerado de acumulação e sofre com a diminuição do nível de água no período seco, especialmente entre os meses de julho e novembro (Coelho *et al.*, 2006). Seus principais afluentes são os rios Borrachudo, Indaiá, Pará e Paraopebas, sendo o Rio São Francisco o curso principal (Pinto *et al.*, 2014).

2.2. Aquisição de dados limnológicos

Foram realizadas três campanhas de coleta *in situ* entre os anos de 2019 e 2021. A avaliação dos parâmetros físico-químicos de qualidade da água se efetuou por meio da utilização de sondas multiparâmetros em dias coincidentes com a passagem do satélite Sentinel-2. Os instrumentos sensores foram acoplados às sondas Hanna (HI98194) e EXO2 (YSI) e as medições foram realizadas na subsuperfície (30 cm). Os parâmetros selecionados para a medição foram, principalmente, aqueles opticamente ativos, neste caso, chl-a, ficocianina, profundidade do disco de Secchi (transparência), turbidez e total de sólidos em suspensão (TSS). A localização dos pontos amostrados está representada na Figura 2.

Figura 2 – Localização dos pontos amostrados na: a) 1^a campanha; b) 2^a campanha e; c) 3^a campanha



A primeira campanha foi realizada em 4 de outubro de 2019 no período entre 08h00 e 14h00 (horário local). A escolha dos pontos de amostragem foi definida considerando fatores como profundidade, afluentes, presença de matéria orgânica e uso do solo nos arredores. Foram levantados 13 pontos distribuídos ao longo do reservatório entre o barramento e a confluência dos rios São Francisco e Paraopeba. Para tanto, percorreu-se cerca de 80 km da superfície do reservatório. As condições climáticas do dia facilitaram a análise por imagem de satélite, uma vez que o céu sobre o espelho d'água do reservatório estava livre de nuvens, além da baixa atenuação atmosférica.

A segunda campanha foi realizada em 31 de maio de 2020 no período entre 09h00 e 14h00, (horário local). Nesta campanha, foram novamente levantados 13 pontos, assim como na campanha anterior. Assim como no primeiro levantamento, as condições climáticas favoreceram a aquisição dos dados de satélite (ausência de nuvens sobre o espelho d'água e baixa atenuação atmosférica).

A terceira campanha foi realizada no dia 6 de maio de 2021 no período entre 09h00 e 14h00 (horário local). Nesta campanha, além de preservar os 13 pontos levantados nas campanhas anteriores, foram mensurados mais 17 pontos ao longo de 100 km do reservatório, somando-se 30 pontos amostrais.

2.3. Aquisição e processamento de dados de sensoriamento remoto

Os dados obtidos para este estudo são produtos de nível 2 (corrigidos radiometricamente e geometricamente para a parte superior da atmosfera) do sensor MSI, a bordo do satélite Sentinel-2B.

As imagens adquiridas foram convertidas para reflectância da superfície com o objetivo de minimizar possíveis atenuações atmosféricas. Para tanto, utilizou-se o algoritmo desenvolvido por Lonjou *et al.* (2016) denominado *MACCS ATCOR Joint Algorithm* (MAJA). Os dados são fornecidos gratuitamente pelo portal <https://peps.cnes.fr> do PEPS (*Plateforme d'Exploitation des Produits Sentinel*) do Centro Nacional de Estudo Espaciais da França (CNES).

O sensor MSI do Sentinel-2 apresenta 13 bandas (10 na faixa do visível/infravermelho próximo – VNIR e 3 na faixa no infravermelho médio – SWIR). Quatro delas com resolução espacial de 10 m, seis com resolução de 20 m e três dedicadas à eventuais correções com a resolução de 60 m (Tabela 1). Neste trabalho, optou-se por utilizar as bandas que apresentam resolução espacial de 10 m e 20 m.

Tabela 1 – Bandas do sensor MSI/Sentinel-2

Banda	Comprimento de onda central (nm)	Resolução espacial (m)
VNIR	B1 - <i>Coastal aerosol</i>	443
	B2 - Azul	490
	B3 - Verde	560
	B4 - Vermelho	665
	B5 - <i>Vegetation Red Edge</i>	705
	B6 - <i>Vegetation Red Edge</i>	740
	B7 - <i>Vegetation Red Edge</i>	783
	B8 - Infravermelho próximo	842
	B8A - <i>Vegetation Red Edge</i>	865
	B9 - Vapor d'água	945
SWIR	B10 - Infravermelho médio - Cirrus	1375
	B11 - Infravermelho médio	1610
	B12 - Infravermelho médio	2190

A extração dos dados espectrais das imagens de satélite foi realizada com o auxílio do software *Orfeo ToolBox* (OTB), versão 7.1, por meio da ferramenta *Object Radiometric Statistic*. Para esse procedimento, as bandas de 20 m de resolução espacial foram reamostradas para 10 m de forma a homogeneizar o conjunto de dados. Após a reamostragem, foram geradas janelas de 90x90 m onde o ponto central se definiu pelos pontos amostrados. Por fim, a média dos valores espectrais de cada janela foi definida de acordo com as especificidades de cada banda espectral. As informações foram unidas em uma tabela única com os dados limnológicos adquiridos *in situ*.

2.4. Modelos de regressão e análise estatística

Foram realizadas regressões lineares múltiplas por meio do software estatístico *RStudio*, versão 1.5.5109, para os dados referentes às três campanhas. As regressões permitiram analisar a relação entre os dados obtidos *in situ* e os valores médios de reflectância extraídos das janelas estipuladas. A seleção de preditores foi definida pelo método *Stepwise* em um processo híbrido (ou bidirecional).

De maneira a validar os modelos produzidos pela regressão, as seguintes métricas estatísticas foram aplicadas:

- Coeficiente de determinação: r^2 , que permite a análise da proporção da variância do modelo;

- b. Erro médio absoluto: MAE, que indica a distância vertical média obtida entre valores previstos e observados e;
- c. Raiz do erro médio quadrático: RMSE, para a avaliação do erro produzido pelo modelo.

Para analisar a significância estatística dos modelos, utilizou-se o nível de significância de 95% (ρ -value = 0,05).

3. RESULTADOS E DISCUSSÃO

As Tabelas 2, 3 e 4 apresentam os resultados obtidos das medições dos parâmetros chl-a, profundidade do disco de Secchi e turbidez pelas sondas multiparâmetros das 1^a, 2^a e 3^a campanhas, respectivamente. Os valores referentes à presença de TSS e ficocianina encontraram-se abaixo do limite de detecção (LD), não sendo possível retratá-los neste estudo.

Tabela 2 – Valores obtidos *in situ* para os parâmetros opticamente ativos – 1^a campanha

Ponto	Hora	UTM X	UTM Y	Chl-a (µg/L)	Secchi (cm)	Turbidez (NTU)
1	08:55	472262	7985060	1,94	599,60	0,24
2	09:10	471898	7982028	1,78	484,52	0,20
3	09:54	466168	7961381	2,08	448,96	0,65
4	10:06	464238	7961703	2,15	440,75	0,32
5	10:24	459861	7959374	1,63	282,69	0,53
6	10:49	467173	7956256	8,10	244,40	1,06
7	12:10	475088	7944634	5,68	242,33	0,53
8	12:19	476270	7944786	7,76	237,55	1,11
9	13:16	481571	7918890	4,40	215,90	1,04
10	13:27	480992	7918858	4,38	211,85	1,10
11	13:34	480484	7918858	5,35	243,74	1,08
12	13:47	483356	7920529	4,30	219,42	1,08
13	13:55	482352	7920516	3,82	199,51	1,11

Tabela 3 – Valores obtidos *in situ* para os parâmetros opticamente ativos – 2^a campanha

Ponto	Hora	UTM X	UTM Y	Chl-a (µg/L)	Secchi (cm)	Turbidez (NTU)
1	09:19	471795	7982077	0,66	180	6,27
2	10:48	459964	7959407	0,60	280	2,21
3	10:58	461166	7958790	0,61	275	2,04
4	11:08	465408	7956795	0,72	315	0,98
5	12:16	475104	7944913	0,83	515	6,22
6	12:19	476125	7944744	0,66	400	0,72
7	12:43	477924	7933026	0,77	375	0,88
8	13:05	480297	7918670	0,73	285	1,61
9	13:11	480731	7918722	0,70	270	1,70
10	13:18	481749	7919093	0,84	280	1,84
11	13:26	483385	7920367	0,75	265	1,88
12	13:34	482370	7920965	0,74	260	1,91
13	13:55	480412	7929195	0,81	420	1,02

Tabela 4 – Valores obtidos *in situ* para os parâmetros opticamente ativos – 3^a campanha

Ponto	Hora	UTM X	UTM Y	Chl-a (µg/L)	Secchi (cm)	Turbidez (NTU)
1	9:24	472446	7983025	1,19	400	0,99
2	9:29	471230	7980642	0,95	425	0,97
3	9:44	467297	7975654	0,88	370	1,18
4	9:55	469244	7972614	1,51	375	1,19
5	10:09	468337	7968019	1,11	350	1,26
6	10:21	467133	7964633	0,98	310	1,51
7	10:33	465844	7961221	0,97	375	1,08
8	10:38	466832	7960476	1,17	360	1,04
9	10:44	468348	7960300	1,33	0*	0,81
10	10:57	463143	7960339	0,74	375	1,40
11	11:11	465180	7955459	1,38	300	1,38
12	11:15	465748	7955443	1,93	290	1,40
13	11:21	466767	7955640	1,66	270	1,36
14	11:29	469924	7954845	1,64	280	1,41
15	11:33	470137	7954374	1,45	290	1,44
16	11:36	470195	7953737	2,04	260	1,58
17	11:51	477645	7951836	1,48	260	1,60
18	11:55	477899	7951158	2,17	240	1,81
19	12:00	477735	7950279	1,31	260	1,45
20	12:18	475597	7942193	1,05	300	1,46
21	12:25	474804	7940224	1,12	300	1,39
22	12:37	476956	7935590	1,34	310	1,24
23	12:54	479926	7929865	1,49	310	1,35
24	13:15	480334	7918155	1,49	250	1,52
25	13:19	481150	7918440	1,70	270	1,44
26	13:22	482000	7918587	2,11	260	1,62
27	13:28	482785	7920085	3,16	220	1,93
28	13:31	483756	7920048	3,06	230	2,14
29	13:35	483962	7920800	3,06	240	1,95
30	13:40	481690	7920259	2,37	220	2,51

* Disco de Secchi atingiu o fundo do reservatório

Um dos principais objetivos do monitoramento dos parâmetros de qualidade da água é a verificação de possíveis alterações no corpo hídrico que podem ser responsáveis por efeitos deletérios. Em reservatórios como o de Três Marias, preocupa-se com o crescimento de algas como uma consequência do processo de eutrofização, resultante do aumento da concentração de nutrientes (fósforo e nitrogênio) nos ecossistemas aquáticos. Porém, a partir de uma análise da situação momentânea baseada nos dados obtidos nas Tabelas 2, 3 e 4 não apresenta nenhuma propensão de afloramentos algais, visto que a concentração de chl-a manteve-se dentro dos padrões esperados (concentração média: 1^a campanha 4,1 µg/L; 2^a campanha 0,7 µg/L; 3^a campanha 1,5 µg/L). Este fato justifica a ausência de ficocianina (concentração < LD) que é característica de locais com alta quantidade do pigmento clorofila (geralmente locais de floração).

Além disso, os demais parâmetros monitorados corroboram com a alta qualidade da água do Reservatório de Três Marias, caracterizado por pH próximo a neutralidade, OD médio na faixa de 6 mg/L e baixa incidência de matéria orgânica. Os valores de turbidez e transparência podem ser correlacionados de forma positiva, sendo diretamente proporcionais. Não ocorreu nenhuma variação

brusca desses parâmetros, mantendo-se sempre uma turbidez baixa e um alto índice de transparência, sendo os maiores valores de turbidez encontrados, em geral, à entrada do Rio Paraopeba. Com valores baixos de turbidez (média de 1,5 NTU, somadas as três campanhas) já era esperado que os valores referentes a presença de sólidos suspensos estivessem abaixo do LD.

Com os dados limnológicos organizados foi possível gerar os conjuntos de dados utilizando a abordagem *Stepwise* híbrida. A Tabela 5 descreve as equações resultantes dos modelos de regressão gerados para as três campanhas, os respectivos coeficientes de determinação e as métricas de acurácia utilizadas para avaliar os modelos propostos. O p -value considerado para o desenvolvimento dos modelos foi $< 0,05$ para todos os parâmetros.

Tabela 5 – Equações e métricas de regressão dos modelos de qualidade da água

Data	Variável dependente	Equação	r^2	MAE	RMSE	p -value
04/10/2019	Chl-a	$22,084 + (-1417,997 * \mathbf{B2}) + (288,606 * \mathbf{B3}) + (1043,172 * \mathbf{B4})$	0,76	0,741	0,893	$< 0,01$
	Secchi	$407,1 + (25338,2 * \mathbf{B2}) + (-22325,8 * \mathbf{B3})$	0,85	33,58	43,49	$< 0,01$
	Turbidez	$0,3328 + (-58,5635 * \mathbf{B2}) + (56,0627 * \mathbf{B3})$	0,75	0,123	0,159	$< 0,01$
31/05/2020	Chl-a	$1,6351 + (-43,5460 * \mathbf{B2}) + (55,6113 + \mathbf{B5}) + (298,4832 * \mathbf{B6}) + (-333,5344 * \mathbf{B7}) + (-164,6090 * \mathbf{B8}) + (232,1883 * \mathbf{B8A}) + (-97,9996 * \mathbf{B12})$	0,76	0,019	0,023	0,02
	Secchi	$1127,9 + (-44990 * \mathbf{B2}) + (322784,3 * \mathbf{B6}) + (-433747,2 * \mathbf{B8}) + (262452,1 * \mathbf{B8A}) + (-217077,6 * \mathbf{B11})$	0,31	54,48	65,6	0,17*
	Turbidez	$5,513 + (-360,712 * \mathbf{B3}) + (752,722 * \mathbf{B4}) + (-4020,233 * \mathbf{B8}) + (4332,260 * \mathbf{B8A})$	0,81	0,477	0,627	$< 0,01$
06/05/2021	Chl-a	$2,907 + (-222,660 * \mathbf{B2}) + (95,482 * \mathbf{B3}) + (84,254 * \mathbf{B4})$	0,42	0,344	0,456	$< 0,01$
	Secchi	$-322,9 + (30651,1 * \mathbf{B2}) + (-26100,5 * \mathbf{B5}) + (-77385,8 * \mathbf{B8}) + (84892,2 * \mathbf{B8A})$	0,53	< LD	< LD	$< 0,01$
	Turbidez	$0,6163 + (-116,5407 * \mathbf{B2}) + (104,8793 * \mathbf{B3})$	0,71	< LD	< LD	$< 0,01$

* Modelo não considerado válido usando o p -value $< 0,05$

Em termos gerais, os modelos de regressão múltipla gerados para a primeira campanha, em setembro de 2019, apresentaram os mais elevados valores de r^2 , variando entre 0,75 e 0,85. Observa-se que as bandas espectrais do visível ($\mathbf{B2}$, $\mathbf{B3}$ e $\mathbf{B4}$) se mostraram bons preditores quando associadas ao instrumento MSI.

Os modelos gerados para o conjunto de dados da segunda campanha, de maio de 2020, apresentaram valores elevados de r^2 para os parâmetros de chl-a e turbidez (0,76 e 0,81,

respectivamente). Entretanto, para transparência, o melhor resultado encontrado de r^2 pelo método adotado foi de 0,31 ($p\text{-value} = 0,17$), o que torna este um modelo não válido para as análises. Todos os três parâmetros trabalhados exigiram a inclusão de alguma banda espectral além das bandas do visível (B2, B3 e B4): para chl-a, do infravermelho próximo (B5, B6, B7, B8 e B8A) e do infravermelho médio (B12); para transparência de Secchi, do infravermelho próximo (B6, B8 e B8A) e do infravermelho médio (B11); para turbidez, do infravermelho próximo (B8 e B8A).

Os modelos gerados a partir dos dados da terceira campanha, de maio de 2021, apresentou valores medianos a elevados de r^2 : 0,42 para chl-a, 0,53 para transparência do disco de Secchi e 0,71 para turbidez. A composição das equações para os melhores modelos de chl-a e turbidez utilizaram apenas bandas do visível. O parâmetro de transparência utilizou, além da banda do azul, bandas do infravermelho próximo (B5, B8 e B8A). Apesar de valores de r^2 menos elevados se comparados à primeira campanha, o erro associado a estes modelos foi significativamente menor, onde transparência e turbidez não alcançaram nem o mínimo do LD. É possível que este fato se associe ao maior número de amostras levantadas nesta campanha.

A banda 1 (banda *Coastal*) do sensor MSI foi excluída das análises, uma vez que há um aparente problema de calibração para esta banda.

Após a avaliação do desempenho de cada modelo, os dados das três campanhas foram agrupados em uma única tabela para a geração de um modelo único. A Tabela 6 apresenta as equações resultantes dos modelos de regressão gerados.

Tabela 6 – Equações e métricas de avaliação para os modelos finais

Variável dependente	Variável independente	Equação	r^2	$p\text{-value}$	MAE	RMSE
Chl-a (µg/L)	B3, B4, B5, B8A, B12	$-0.6325 + (143.6986 * B3) + (-973.3626 * B4) + (1293.2370 * B5) + (-542.2804 * B8A) + (114.7752 * B12)$	0,63	< 0,01	0,642	0,950
Secchi (cm)	B2, B3, B6, B8A	$422.49 + (17536.52 * B2) + (-12812.89 * B3) + (-51818.12 * B6) + (46074.86 * B8A)$	0,41	< 0,01	< LD	< LD
Turbidez (NTU)	B2, B4, B6, B8A	$2.4429 + (-109.1353 * B2) + (255.4971 * B4) + (-587.1397 * B6) + (418.4362 * B8A)$	0,50	< 0,01	0,363	0,699

Os modelos de regressão múltipla dos dados agrupados apresentaram valores de r^2 entre 0,41 (transparência) e 0,63 (chl-a) e $p\text{-value} < 0,01$. As Figuras 3, 4 e 5 apresentam os mapas com os resultados dos modelos finais válidos gerados para chl-a, transparência e turbidez para o sensor MSI/Sentinel-2 referentes às três campanhas realizadas.

Figura 3 – Modelo aplicado à 04/10/2019 para o sensor MSI/Sentinel-2: a) chl-a; b) transparência e; c) turbidez

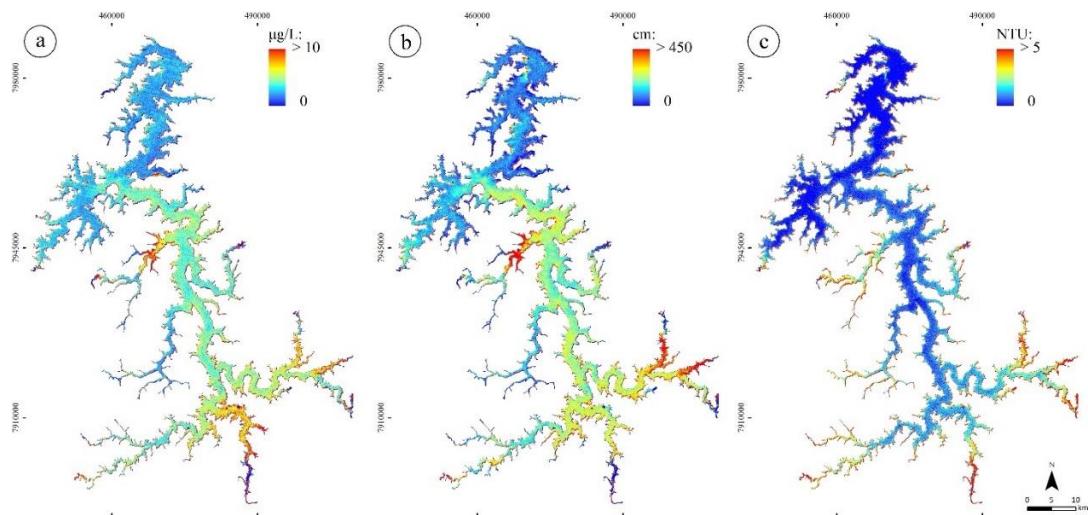


Figura 4 – Modelo aplicado à 31/05/2020 para o sensor MSI/Sentinel-2: a) chl-a; b) transparência e; c) turbidez

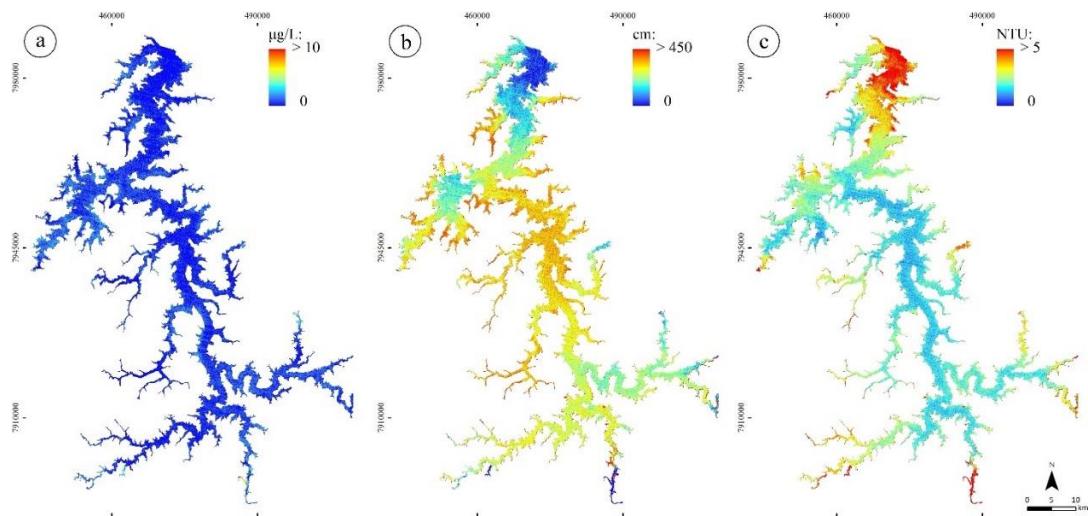
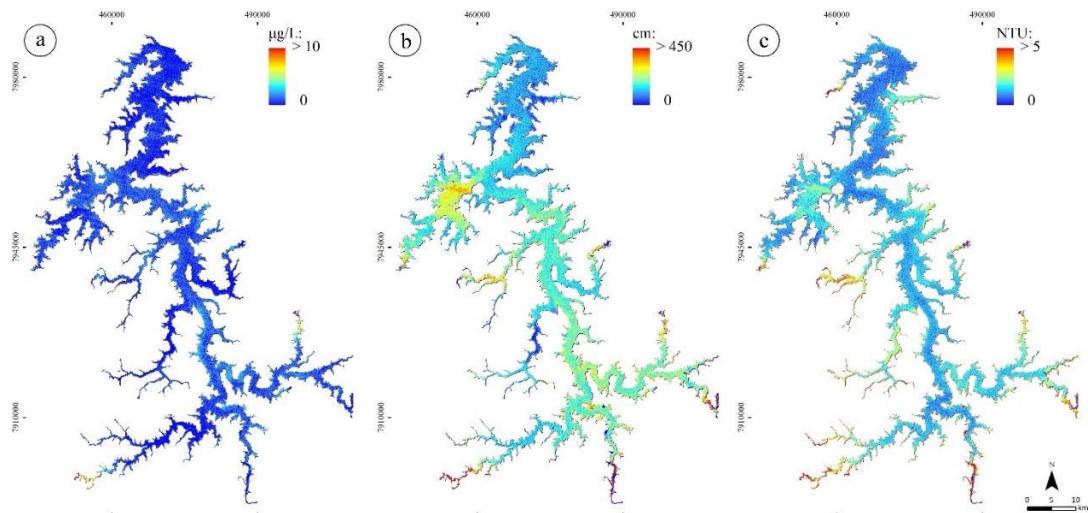


Figura 5 – Modelo aplicado à 06/05/2021 para o sensor MSI/Sentinel-2: a) chl-a; b) transparência e; c) turbidez



4. CONSIDERAÇÕES FINAIS

A partir dos dados limnológicos amostrados e das informações espectrais do sensor MSI/Sentinel-2 foi possível gerar modelos de regressão linear múltipla para os componentes opticamente ativos chl-a, transparência do disco de Secchi e turbidez do Reservatório de Três Marias. O instrumento MSI se mostrou, na maior parte das aplicações, uma ferramenta efetiva para estimativa destes parâmetros. Os resultados alcançados com os dados das três campanhas realizadas (2019, 2020 e 2021) indicam elevado grau de homogeneidade do reservatório e boa qualidade de água.

Deseja-se, futuramente, realizar novas campanhas de forma que os conjuntos de dados sejam mais robustos tornando os modelos mais aprimorados.

REFERÊNCIAS

- BLANCHON, D. (2009). *Atlas mondial de l'eau: de l'eau pour tous?* Editions Autrement Paris, 79 p.
- COELHO, R.M.P. (2006). *Estudo técnico-científico visando a delimitação de parques aquícolas nos lagos das usinas hidrelétricas de Furnas e Três Marias.* SECTES - Secretaria de Estado de Ciência, Tecnologia e Ensino Superior de Minas Gerais, MG, 131 p.
- LONJOU, V.; DESJARDINS, C.; HAGOLLE, O.; PETRUCCI, B.; TREMAS, T.; DEJUS, M.; MAKARAU, A.; AUER, S. (2016). “*MACCS-ATCOR joint algorithm (MAJA)*”. *Remote Sensing of Clouds and the Atmosphere XXI* 10001, pp. 1 – 13.
- MISHRA, D.; OGASHAWARA, I.; GITELSON, A. (2017). *Bio-optical modeling and remote sensing of inland Waters.* Elsevier Science, 324 p.
- PINTO, C.E.T.; MENEZES, P.H.B.J.; MARTINEZ, J.M.; ROIG, H.L.; VILLAR, R.A.E. (2014). “*Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias*”. *Revista Brasileira de Engenharia Agrícola e Ambiental* 18(5), pp. 507 – 516.
- VON SPERLING, M. (2007). *Estudos e modelagem da qualidade da água de rios.* DESA/UFMG MG, 588 p.

AGRADECIMENTOS – Este trabalho foi produzido no âmbito de um projeto mais amplo intitulado “Monitoramento Inteligente da Qualidade da Água em Reservatórios Hidrelétricos Através do Desenvolvimento de um Algoritmo Fotogramétrico” e financiado pela Companhia Energética de Minas Gerais (CEMIG, projeto GT-0607). Os autores são gratos à equipe GT-0607 que tornou este artigo possível.

ANEXO D – Artigo: Estimativa de parâmetros não-opticamente ativos de qualidade da água a partir de sensores Sentinel-2/MSI e Landsat-8/OLI

PIZANI, F.M.C.; FERREIRA, A.F.F.; MAILLARD, P.. Estimativa de parâmetros não-opticamente ativos de qualidade da água a partir de sensores Sentinel-2/MSI e Landsat-8/OLI. Caminhos da Geografia (UFU. Online), v. 23, p. 399-414, 2022.

ESTIMATIVA DE PARÂMETROS NÃO-OPTICAMENTE ATIVOS DE QUALIDADE DA ÁGUA A PARTIR DE SENsoRES SENTINEL-2/MSI E LANDSAT-8/OLI

Fernanda Mara Coelho Pizani

Universidade Federal de Minas Gerais – UFMG

Instituto de Geociências, Belo Horizonte, Minas Gerais, Brasil

fm.coelho@yahoo.com.br

Adrielly Fonseca Fialho Ferreira

Universidade Federal de Minas Gerais – UFMG

Departamento de Engenharia Sanitária e Ambiental, Belo Horizonte, Minas Gerais, Brasil

adrielly.fonseca@gmail.com

Philippe Maillard

Universidade Federal de Minas Gerais – UFMG

Instituto de Geociências, Belo Horizonte, Minas Gerais, Brasil

philippermaillard@yahoo.com.br

RESUMO

O monitoramento de parâmetros indicadores da qualidade da água em reservatórios é uma necessidade prevista em lei, uma vez que a demanda pelos recursos hídricos expandiu-se em razão das suas múltiplas finalidades. Sensores remotos passivos mensuram a reflectância da radiação solar na superfície da água permitindo que parâmetros não-opticamente ativos sejam avaliados pela inferência de parâmetros opticamente ativos. Considerando que modelos empíricos dificilmente são empregados em áreas diferentes daquelas onde foram concebidos, o objetivo deste trabalho consiste em aplicar modelos de parâmetros não-opticamente ativos, desenvolvidos anteriormente (outubro/2019) em dados coletados em outra época (maio/2020), considerando o mesmo reservatório (Reservatório de Três Marias/MG), de forma a avaliar a replicabilidade destes modelos. Empregou-se a abordagem desenvolvida por Pizani et al. (2020) utilizando as mesmas bandas espectrais como preditores em análise de regressão múltipla para os parâmetros: condutividade elétrica, sólidos dissolvidos totais e oxigênio dissolvido. Os resultados indicam elevado coeficiente de determinação entre dados medidos *in situ* e a reflectância espectral com destaque para o melhor desempenho do sensor MSI/Sentinel-2 ($r^2 > 0,71$) comparado ao sensor OLI/Landsat ($r^2 > 0,50$). Estes resultados mostram avanços da pesquisa para o monitoramento remoto, que possibilita a redução de custos para os órgãos públicos ou privados.

Palavras-chave: Sensoriamento Remoto. Sensores Remotos Passivos. Qualidade da Água. Reflectância Espectral da Água.

ESTIMATION OF NON-OPTICALLY ACTIVE WATER QUALITY PARAMETERS FROM SENTINEL-2/MSI AND LANDSAT-8/OLI SENSORS

ABSTRACT

Monitoring water quality parameters in reservoirs is required by law in Brazil, especially considering the increasing demand for water resources and their multiple use. Passive remote sensors measure the reflectance of solar radiation on the water surface and can allow non-optically active parameters to be evaluated through their relation with optically active parameters. Considering that empirical models are rarely used in areas other than those for which they were conceived, the objective of this paper is to apply previously developed non-optically active parameter models (October/2019) to image data from a later date (May/2020) for the same reservoir (Três Marias Reservoir/MG) and, hence, assess the replicability of these models. The approach uses the same spectral bands as predictors in the multiple regression models developed by Pizani et al. (2020) to estimate three parameters: electrical conductivity, total dissolved solids and dissolved oxygen. The results indicate high coefficient of determination between the data measured *in situ* and the spectral reflectance, highlighting the better performance of the MSI/Sentinel-2 sensor ($r^2 > 0.71$) compared to the OLI/Landsat sensor ($r^2 > 0.50$). These results show advancement in remote sensing research to monitor water bodies while reducing surveying costs.

Keywords: Remote Sensing. Passive Remote Sensors. Water Quality Parameters. Spectral Reflectance of Water.

INTRODUÇÃO

A água é um recurso natural indispensável para qualquer organismo vivo. Ela é o constituinte inorgânico de maior presença na matéria viva compondo mais de 60% do peso humano e atingindo 98% da matéria de determinados animais aquáticos (VON SPERLING, 2007). Sua importância para a manutenção da vida é inquestionável. Cerca de 40% da produção agrícola mundial é dependente da agricultura irrigada. Os processos naturais, como a transpiração e a evapotranspiração, dependem dos ecossistemas aquáticos, que podem ser muito frágeis. Apesar dessa necessidade vital, mais de um bilhão de pessoas no mundo não tem acesso à água potável (BLANCHON, 2009).

Nos últimos cem anos, a pressão sobre os recursos de água doce tem aumentado drasticamente; é estimado que o uso da água tenha aumentado duas vezes mais que o crescimento da população mundial (UNESCO-WAPP, 2006). Entre 1995 e 2008, o consumo mundial de água aumentou de 37,3% (ARTO; ANDREONI; RUEDA-CANTUCHE, 2016). Com o aumento da demanda e a diminuição da disponibilidade, cresce também a necessidade de avaliar a qualidade da água para que a sua utilização ocorra de maneira adequada para a população que dela se beneficia. O monitoramento dos parâmetros que indicam a qualidade da água *in situ*, seja por telemetria ou manualmente, demanda custos altos e limita a amostragem (PU et al., 2019). A possibilidade de efetuar o monitoramento remotamente representa uma alternativa de baixo custo muito atraente.

Os sensores passivos aplicados aos estudos de água medem a reflexão da radiação solar (radiância) ou a energia emitida (emitância) na superfície aquática. A resposta do sensor, fruto da interação entre a luz e o corpo d'água, é dada de acordo com os constituintes presentes nos primeiros decímetros a metros da superfície. Os diferentes sensores captam por meio de imagens os efeitos da relação entre a radiação solar refletida (nos processos de absorção e espalhamento) e os componentes presentes na água, além de fornecerem informações espectrais que servem como subsídio para quantificar determinados parâmetros de qualidade da água (BARBOSA; NOVO; MARTINS, 2019). O uso de sensores orbitais (como os da série Landsat e Sentinel) aplicado ao ambiente aquático apresenta características adequadas para estimar a qualidade da água: espectro óptico coberto, tempo de revisita, área de cobertura, influência atmosférica, entre outras variáveis (MERTES et al., 2004).

Processos de absorção e espalhamento dos componentes opticamente ativos da água podem ser estudados em diferentes comprimentos de onda. Quando em contato com a água, os fótons de luz interagem principalmente com quatro constituintes opticamente ativos que são a água pura, os pigmentos fotossintetizantes presentes no fitoplâncton, os materiais particulados suspensos e a matéria orgânica dissolvida colorida (MCCOY, 2005). A resposta espectral que resulta da interação com a radiação solar possibilita a estimativa da qualidade da água por meio destes constituintes opticamente ativos (BARBOSA; NOVO; MARTINS, 2019).

No entanto, além dos parâmetros opticamente ativos, outros parâmetros físico-químicos e/ou biológicos que possuem alto grau de importância ambiental podem ser utilizados como indicadores da qualidade da água. Estes indicadores podem ser classificados como parâmetros não baseados em cores e, portanto, não-opticamente ativos (NOA). Grande parte dos estudos focam na estimativa de nitrogênio e fósforo (LI; HUANG; WANG, 2020). A simples reflectância da água não possibilita a detecção dos parâmetros NOA, uma vez que as características ópticas e a relação sinal-ruído são relativamente baixas. Entretanto, estes parâmetros podem ser inferidos indiretamente aos parâmetros opticamente ativos (OA), como a clorofila-a (chl-a), total de sólidos suspensos (TSS) e a matéria orgânica colorida dissolvida (CDOM) (PU et al., 2019). A alteração de um ou mais desses parâmetros reflete no brilho captado pelo sensor (ABDELMALIK, 2018).

Bem como os parâmetros OA, os NOA podem apresentar baixa correlação na classificação da qualidade da água, e até mesmo erros, caso haja grande diferença no intervalo entre as datas de amostragem e a data de passagem do satélite ou em decorrência da variação climática (TU; SMITH; FILIPPI, 2018; PU et al., 2019). A alteração de um parâmetro NOA e as mudanças sazonais podem afetar os resultados de correlação entre os dados de qualidade da água e a reflectância. Frente a isso, é importante considerar a estação e a condição climática à qual o estudo está submetido (ABDELMALIK, 2018).

Existem vários parâmetros NOA passíveis de estimativa indireta por sensoriamento remoto devido à sua relação com outras variáveis. A literatura apresenta a estimativa de alguns desses parâmetros: potencial de hidrogênio (pH) (WANG et al., 2012; WANG et al., 2014; ABDELMALIK, 2018; PU et al., 2019; LI; HUANG; WANG, 2020) condutividade elétrica (ABDELMALIK, 2018; AVDAN et al., 2019), salinidade, alcalinidade (ABDELMALIK, 2018), demanda química de oxigênio (ALPARSLAN; COSKUN; ALGANCI, 2009; WANG et al., 2012; WANG et al., 2014; HUO et al., 2014; XIANG et al., 2015, PU et al., 2019; LI; HUANG; WANG, 2020), absorção de material não pigmentado (JIANG et al., 2010), demanda biológica de oxigênio

(ALPARSLAN; COSKUN; ALGANCI, 2009; WANG et al., 2012), oxigênio dissolvido (WANG et al., 2012; WANG et al., 2014; PU et al., 2019; LI; HUANG; WANG, 2020), nitrogênio total (LIU et al., 2015; TU; SMITH; FILIPPI, 2018), fósforo total (LIU et al., 2015; XIONG et al., 2019), carbono orgânico dissolvido (TOMING et al., 2016; CHEN et al., 2017), carbono orgânico particulado (HADJIMITSIS e CLAYTON, 2011) e carbono orgânico total (ABDELMALIK, 2018).

As abordagens mais comumente empregadas na literatura para estimativa de parâmetros NOA incluem a estudos acerca da concentração, principalmente, de fósforo total, salinidade da superfície do mar, oxigênio dissolvido, demanda bioquímica de oxigênio e demanda química de oxigênio (GHOLIZADEH; MELESSE; REDDI, 2016). Para a estimativa dos parâmetros NOA, diferentes técnicas estatísticas e modelos de regressão foram desenvolvidos ao longo dos anos (ABDELMALIK, 2018; PU et al., 2019). Neste estudo, três importantes parâmetros NOA de qualidade da água foram selecionados em decorrência de campanhas realizadas nos anos de 2019 e 2020. São eles: condutividade elétrica (CE), sólidos dissolvidos totais (SDT) e oxigênio dissolvido (OD).

A CE da água é um parâmetro que pode ser definido como a expressão numérica da capacidade de uma água conduzir a corrente elétrica. Esse parâmetro está associado diretamente às concentrações das substâncias iônicas dissolvidas na água representando, portanto, a medida indireta da concentração de poluentes inseridos no meio (CETESB, 2019). E esses poluentes, conforme suas características, também podem influenciar a alteração de outros parâmetros de qualidade da água tais como: turbidez, carbono orgânico total e cor.

Nesse sentido, os sólidos dissolvidos também possuem relação com a CE, uma vez que representa a concentração de substâncias (orgânicas ou inorgânicas) em água. Essa variável pode ser relacionada à cor, sendo um componente opticamente ativo, definido como o grau de redução de intensidade que a luz sofre ao atravessá-la (absorção de parte da radiação eletromagnética) (CETESB, 2019). A cor da água está vinculada principalmente pela dissolução de ácidos húmicos e fulvicos, substâncias naturais resultantes da decomposição parcial de folhas ou outros substratos. Entretanto, esse parâmetro físico também pode ser afetado por lançamentos de efluentes no corpo hídrico (VON SPERLING, 2007).

O OD é uma variável química importante pois indica a capacidade de um corpo d'água natural em manter a vida aquática e é indispensável na manutenção de processos de autodepuração em sistemas aquáticos (VON SPERLING, 2007). Teores elevados de OD associados à elevação de pH podem indicar o crescimento excessivo de algas que, durante a fotossíntese, promovem a inserção de oxigênio no meio. Isto ocorre principalmente em lagos de baixa velocidade de renovação da água nos quais podem se formar crostas verdes de algas à superfície (CETESB, 2019).

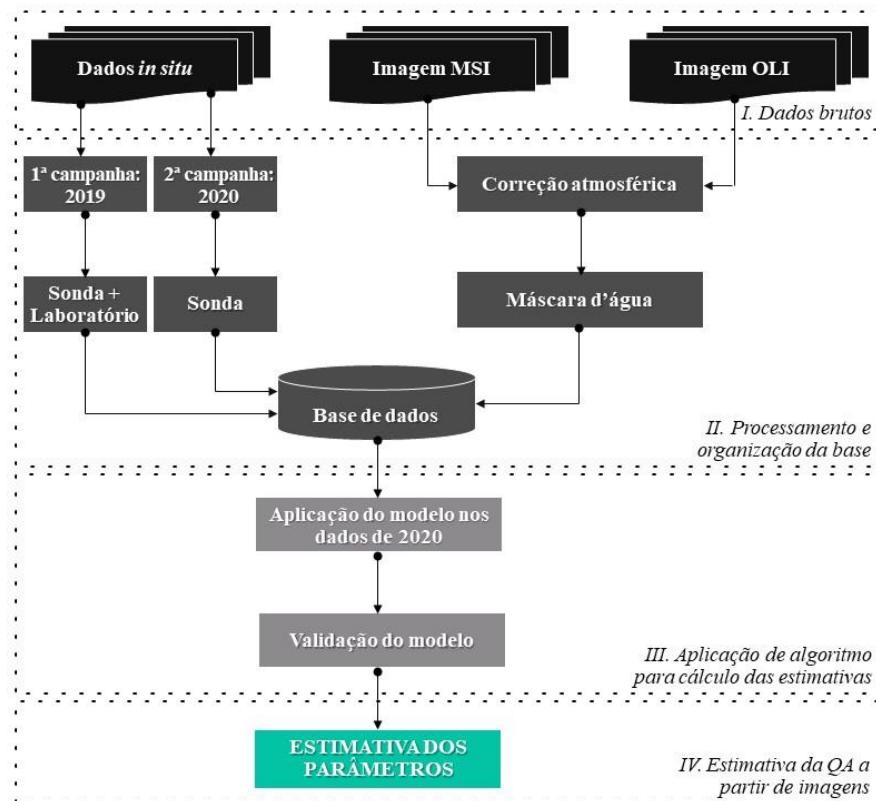
Neste artigo, utilizou-se a capacidade de estimar três parâmetros NOA de qualidade da água por meio de análises estatísticas associadas ao sensoriamento remoto passivo. Dados de sensores remotos provenientes dos satélites Landsat-8 e Sentinel-2 foram empregados de forma a estimar os níveis de qualidade da água *in situ* e as imagens de satélite disponíveis. Sabe-se que modelos NOA raramente são exportáveis para outras áreas uma vez que, para aplicar a comparação regional entre parâmetros NOA e parâmetros opticamente ativos, os componentes NOA necessitam que algoritmos específicos do lugar sejam desenvolvidos (TOPP et al., 2020).

Neste sentido, o objetivo do presente trabalho foi aplicar modelos empíricos de parâmetros NOA desenvolvidos em outubro de 2019 por Pizani et al. (2020) para dados de maio de 2020, considerando o reservatório de Três Marias, localizado em Minas Gerais, a fim de avaliar a aplicabilidade do modelo em épocas do ano e condições do reservatório diferenciadas. Os parâmetros de qualidade da água aqui levantados foram: CE, SDT e OD. Acredita-se que as informações obtidas podem fornecer subsídio no planejamento, reduzindo custos e auxiliando a gestão pública e privada no monitoramento de reservatórios.

METODOLOGIA

A metodologia utilizada nesta pesquisa foi baseada em análises de regressão múltiplas, igualmente utilizada por Pizani et al. (2020). Os autores desenvolveram o modelo que aqui foi aplicado na mesma área de estudo, porém tendo como referência uma única campanha. Para alcançar os resultados, os dados foram organizados em conjuntos de maneira a facilitar o desenvolvimento dos procedimentos metodológicos descritos abaixo. O fluxograma sintetizando estes agrupamentos pode ser observado na Figura 1.

Figura 1 - Fluxograma das etapas desenvolvidas para estimativa dos parâmetros de qualidade da água.



Elaborado pelos autores (2021).

Os dados brutos se caracterizam pelas imagens de satélite (Landsat-8 e Sentinel-2) dos dias das campanhas (04/10/2019 e 31/05/2020) além dos dados obtidos *in situ* pela sonda e por amostras de água. Os dados foram tabulados e preparados a fim de iniciar a segunda etapa de processamento e organização da base de dados.

Na segunda etapa os dados amostrais da coleta de água referentes à primeira campanha foram analisados em laboratório e somados aos dados obtidos pela sonda. As imagens de satélite passaram por um processo de correção atmosférica e posterior extração de máscara d'água. Os dados foram, então, organizados em uma base de dados unificada.

A terceira etapa consiste na aplicação do algoritmo para o cálculo das estimativas. O modelo desenvolvido na primeira etapa foi aplicado aos dados da segunda etapa e validados com o auxílio de pacotes estatísticos. Uma vez validados, os modelos foram aplicados às imagens de satélite para estimar a qualidade da água no Reservatório de Três Marias.

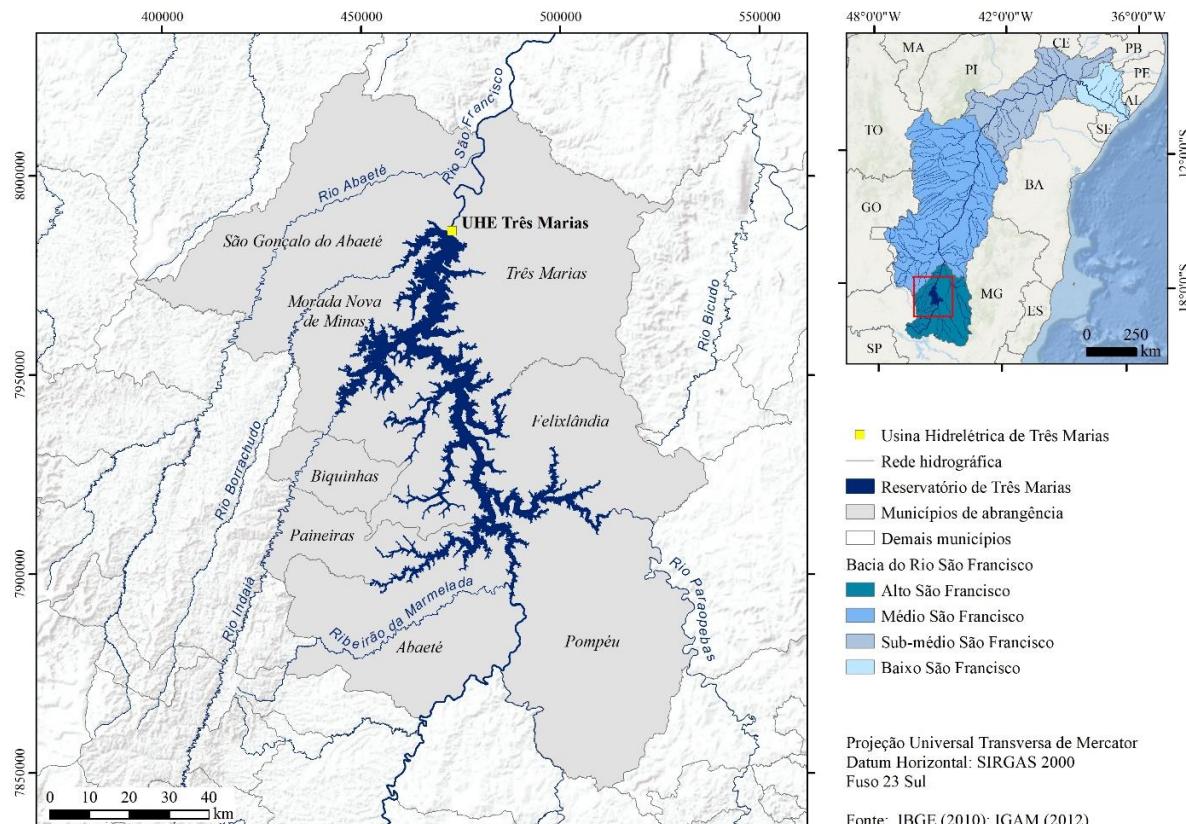
As especificidades das etapas descritas serão abordadas nos subtópicos que se seguem.

Área de estudo e planejamento amostral

O rompimento da barragem de rejeitos em Brumadinho que atingiu o Córrego do Feijão provocou danos direto à qualidade da água no Rio Paraopebas (THOMPSON et al., 2020; VERGILIO et al., 2020), que é um dos principais tributários do Reservatório de Três Marias. Por esse motivo e desde então, estudos de monitoramento da qualidade da água estão sendo realizados na região do reservatório para avaliar a qualidade da água a sua jusante (CIONEK et al., 2019). Portanto, a área de estudo desse trabalho

contempla o Reservatório de Três Marias, localizado no contexto hidrográfico da Sub-bacia do Alto Rio São Francisco (Figura 2). A represa é considerada um dos reservatórios mais antigos do Brasil (CACHAPUZ, 2006). É o nono maior reservatório do país quanto à área (1.090km²) e o sexto maior quanto ao volume (21km³) (VON SPERLING, 1999).

Figura 2 - Localização da área de estudo.



Elaborado pelos autores (2021).

Como estratégia, este estudo realizou duas coletas *in situ* que compõem o conjunto de dados. A primeira campanha foi realizada no dia 04 de outubro de 2019. Na ocasião, as condições climáticas previstas eram favoráveis às imagens de satélite, com indicativo de céu claro e irrelevante presença de nuvens. A segunda campanha foi realizada no dia 31 de maio de 2020, quando a previsão do tempo era, igualmente, favorável.

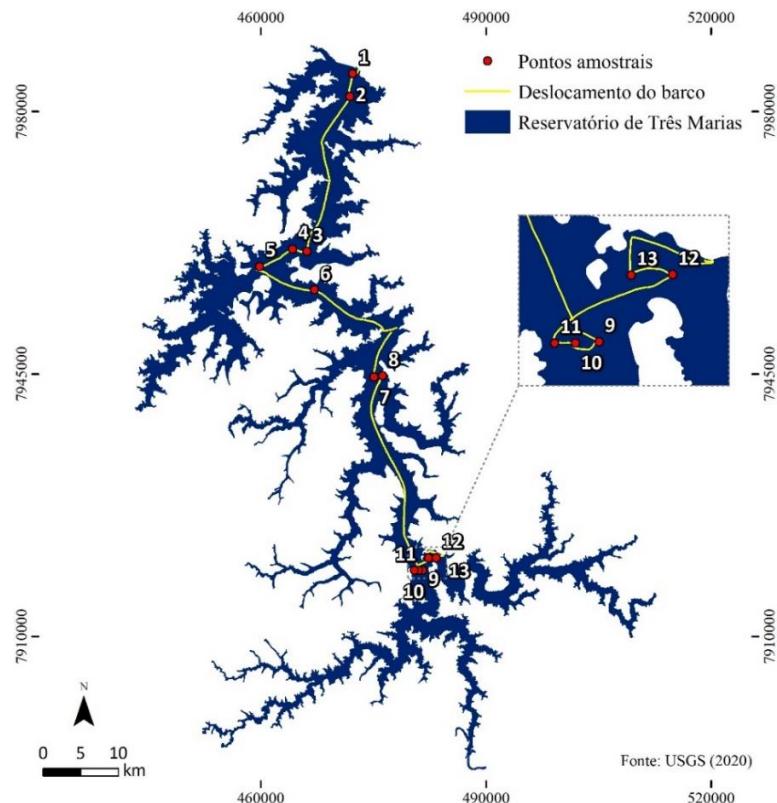
Ambas as campanhas foram idealizadas de acordo com a coincidência de datas quanto à passagem dos satélites Sentinel-2 e Landsat-8, que seriam sincronizados com as coletas em campo. Os dois satélites se coincidem a cada 80 dias e suas passagens ocorrem por volta das 10h00 da manhã (horário local). Desta forma, ambas as campanhas ocorreram durante o período da manhã, entre os horários de 08h00 e 14h00.

Coleta dos dados referentes aos parâmetros de qualidade da água

Para a realização da coleta dos dados limnológicos foi utilizado um barco a motor. O trajeto foi iniciado próximo à Usina Hidrelétrica de Três Marias, junto à área do barramento, e finalizado próximo à confluência dos rios Paraopebas e São Francisco. O percurso foi orientado, principalmente, pela calha do rio São Francisco e distou cerca de 85km ao longo do espelho d'água do reservatório. Em ambas as campanhas,

foram levantados 13 pontos amostrais coincidentes nos quais foram obtidos os parâmetros de qualidade da água (Figura 3).

Figura 3 - Localização dos pontos de amostragem.



Elaborado pelos autores (2021).

Para registro e replicação dos pontos amostrais da primeira campanha as coordenadas geográficas dos pontos foram coletadas e armazenadas em um *Global Navigation Satellite System* (GNSS) de navegação. Na segunda campanha, realizada em maio de 2020, os parâmetros NOA foram determinados utilizando uma sonda multiparâmetros (YSI ProDSS) e os pontos foram mantidos conforme sua localização espacial na primeira campanha. As análises de SDT foram realizadas no Departamento de Engenharia Ambiental e Sanitária (DESA) da Universidade Federal de Minas Gerais (UFMG) atendendo às recomendações do *Standard Methods for the Examination of Water and Wastewater* (APHA, 2012).

Durante as campanhas foram medidos vários parâmetros *in situ* de qualidade da água, tanto OA como NOA. No entanto, como foco deste estudo, os parâmetros NOA abordados serão restritos à análise de CE, SDT e OD.

Aquisição de dados de sensoriamento remoto e pré-processamento dos dados

As imagens adquiridas provenientes dos sensores *Multispectral Instrument* (MSI) do satélite Sentinel-2 e *Operational Land Imager* (OLI) do satélite Landsat-8 são produtos de nível 2A (imagens L2A do Sentinel-2/MSI e imagens L2C2 do Landsat-8/OLI), que correspondem à reflectância da base da atmosfera (*Bottom-of-Atmosphere* – BOA). Dados de imagens de nível 2A se diferem de dados de nível 1C devido ao pré-processamento a que estas imagens foram submetidas de maneira a incluir correções radiométricas e geométricas BOA. As imagens correspondentes aos dois períodos possuíam cobertura irrigatória de nuvens acima do espelho d'água além de não haver interferências atmosféricas identificáveis.

As imagens do Landsat-8/OLI correspondem à órbita-ponto 219/073 e foram adquiridas por meio do portal *Earth Explorer* do Serviço Geológico dos Estados Unidos (USGS, 2020). As imagens do Sentinel-2/MSI

correspondem à cena 23KMV e foram adquiridas por meio do portal *Plateforme d'Exploitation des Produits Sentinel* (PEPS, 2020) do *Centre National d'Études Spaciales* (CNES) da França. Ambas as informações estão disponíveis gratuitamente nos respectivos portais. O Quadro 1 descreve as bandas espectrais presentes nos sensores OLI e MSI.

Quadro 1 - Descrição das bandas espectrais dos sensores OLI/Landsat-8 e MSI/Sentinel-2.

Landsat-8/OLI			Sentinel-2/MSI		
Banda	Resolução espectral (nm)	Resolução espacial (m)	Banda	Resolução espectral (nm)	Resolução espacial (m)
B1. Aerossol	433 – 453	30	B1. Aerossol	433 – 453	60
B2. Azul (B)	450 – 515	30	B2. Azul (B)	458 – 523	10
B3. Verde (G)	525 – 600	30	B3. Verde (G)	543 – 578	10
B4. Vermelho (R)	630 – 680	30	B4. Vermelho (R)	650 – 680	10
			B5. Red edge 1	698 – 713	20
			B6. Red edge 2	733 – 748	20
			B7. Red edge 3	773 – 793	20
B5. Infravermelho próximo (NIR)	845 – 885	30	B8. Infravermelho próximo (NIR)	785 – 900	10
			B8A. Red edge 4	855 – 875	20
			B9. Vapor d'água	935 – 955	60
B9. Infravermelho médio (Cirrus)	1360 – 1390	30	B10. Infravermelho médio (Cirrus)	1360 – 1390	60
B6. Infravermelho médio (SWIR 1)	1560 – 1660	30	B11. Infravermelho médio (SWIR 1)	1565 – 1655	20
B7. Infravermelho médio (SWIR 2)	2100 – 2300	30	B12. Infravermelho médio (SWIR 2)	2100 – 2280	20
B8. Pancromática	500 – 680	15			

As imagens de nível 2 adquiridas com processamento para BOA são imagens já corrigidas de forma a amenizar os efeitos de espalhamento e absorção de gases atmosféricos e aerossóis. Esta correção visa a reduzir ao mínimo qualquer interferência atmosférica presente na resposta espectral. Desta forma, o monitoramento da superfície terrestre pode ser efetuado de maneira mais assertiva.

Para os produtos do sensor OLI, o USGS (2018) aplica a correção descrita no Código de Reflectância de Superfície Landsat-8 (LASRC). Para as imagens provenientes do sensor MSI, o PEPS utiliza o pré-

processamento do Algoritmo Conjunto *Maccs-Atcor Joint Algorithm* (MAJA) (LONJOU et al., 2016). As bandas de ambos os sensores apresentam fator de escala de 0,0001, o que permite a conversão dos dados por álgebra simples. Para tal conversão, utilizou-se a ferramenta *Raster Calculator* do sistema de informação geográfica (SIG) comercial ArcGIS versão 10.3 (ESRI, 2014).

As bandas do sensor OLI obtidas pelo LASRC (B1 à B7) são disponibilizadas com a resolução espacial de 30m, enquanto as bandas do sensor MSI são disponibilizadas com as resoluções espaciais de 10m, 20m e 60m em função da banda. Baseado no estudo anterior de Pizani et al. (2020), optou-se por utilizar as bandas disponíveis do sensor OLI de 30m e as bandas reamostradas para 10m do sensor MSI.

Uma vez que a área de pesquisa se restringe ao Reservatório de Três Marias, os pixels correspondentes às porções de terra foram excluídos do estudo, limitando a análise ao espelho d'água da represa. Para tanto, os pixels de água foram extraídos das imagens de satélite por meio do Índice de Diferença Normalizada da Água (NDWI), proposto por McFeeters (1996). Este índice utiliza uma banda do verde e uma banda do infravermelho próximo (NIR), se configurando de acordo com a equação a seguir::

$$NDWI = (\rho(\text{verde}) - \rho(\text{NIR})) \div (\rho(\text{verde}) + \rho(\text{NIR}))$$

onde $\rho(\lambda)$ é a reflectância espectral referente ao comprimento de onda. Este índice varia entre -1 e 1 e tem como limite o valor zero (0). Valores abaixo de 0 são classificados como “não água” e valores acima de 0 são classes relativas à água. Este índice permite maximizar a reflectância da água a partir da banda verde, minimizar a baixa reflectância da água no NIR e destacar o contraste terra/água que a banda infravermelha viabiliza (PEREIRA; LOHMANN; MAGANHOTTO, 2016).

Para extrair as informações dos valores de reflectância de cada ponto amostrado, foram geradas janelas de 90m x 90m, o que equivale a 81 pixels das imagens Sentinel-2/MSI e 9 pixels das imagens Landsat-8/OLI. De acordo com Pizani et al. (2020), este método garante a minimização de possíveis erros como a imprecisão intrínseca ao equipamento GNSS de navegação e o deslocamento do barco a motor durante a coleta devido à ação dos ventos, uma vez que o veículo não foi ancorado.

Análises estatísticas

Para extrair os valores de reflectância espectral das bandas das imagens de satélite correspondentes aos pontos de coleta, foi utilizada a ferramenta *Object Radiometric Statistic* do software livre OTB (Orfeo ToolBox), versão 7.1 (CNES, 2020). Essa ferramenta permite a extração da média, mediana, variância e desvio padrão dos valores identificados nas janelas. Em ambas as campanhas, os valores médios de cada janela foram adotados para análise estatística e consolidados em uma planilha contendo os valores mensurados pelas sondas multiparâmetros.

Análises de regressão lineares múltiplas foram aplicadas de maneira a ajustar os modelos estatísticos referentes aos parâmetros de qualidade da água medidos e as médias espectrais calculadas. As análises de regressão foram realizadas por meio do software livre RStudio, versão 1.5.5019 (R CORE TEAM, 2020) e aplicou os modelos desenvolvidos em Pizani et al. (2020).

RESULTADOS E DISCUSSÃO

Qualidade da água do Reservatório de Três Marias

As águas do Reservatório de Três Marias são enquadradas como classe 2, conforme a Deliberação Normativa COPAM/CERH nº 1 (MINAS GERAIS, 2008), podendo ser utilizadas para diversos fins como o abastecimento público, agricultura, geração de energia, navegação, pesca e aquicultura, turismo e recreação. Dentre os parâmetros de qualidade de água preconizados pela Resolução nº 357, de 17 de março de 2005 do Conselho Nacional de Meio Ambiente (CONAMA) (BRASIL, 2005), observados nas campanhas, o Reservatório de Três Marias possui boa qualidade de água e resultando em baixas alterações dos parâmetros ao longo do percurso, possivelmente devido à existência da barragem de Retiro Baixo localizada no baixo curso do Rio Paraopeba a qual localiza-se a montante do Reservatório de Três Marias (CURTARELLI et al., 2020).

A Tabela 1 apresenta os parâmetros de qualidade da água NOA obtidos nos 13 pontos distribuídos ao longo do Reservatório de Três Marias durante as campanhas de outubro de 2019 e maio de 2020.

Tabela 1 - Parâmetros de qualidade de água NOA referentes à primeira e segunda campanhas.

Ponto	04/10/2019			31/05/2020		
	CE (mV)	SDT (mg/L)	OD (mg/L)	CE (mV)	SDT (mg/L)	OD (mg/L)
1	61,5	51,7	7,40	71,1	47,0	5,34
2	64,1	63,3	7,45	73,6	48,0	5,42
3	77,5	57,5	7,76	74,0	48,0	5,61
4	81,1	160,0	7,68	76,1	49,0	5,44
5	90,0	65,0	7,81	72,2	47,0	7,07
6	92,0	342,5	7,99	76,3	50,0	6,20
7	96,8	78,7	8,17	77,3	50,0	6,20
8	84,2	97,5	7,66	77,9	51,0	6,49
9	79,7	77,5	7,76	78,0	51,0	6,41
10	77,9	127,5	7,68	78,0	51,0	6,36
11	77,2	77,5	7,73	78,0	51,0	6,35
12	75,1	62,5	7,58	77,9	51,0	6,38
13	66,8	82,5	7,62	77,3	50,0	6,39

Fonte - Elaborado pelos autores (2021).

Do ponto de vista ambiental, os valores observados de SDT e OD estão de acordo com os valores máximos permitidos discriminados na Resolução nº 357/2005 do CONAMA (< 500mg/L) para as duas campanhas realizadas. Em relação à CE, não existem na legislação brasileira valores indicados para esse parâmetro (CETESB, 2019). No entanto, de acordo com Von Sperling (2007), as águas naturais apresentam teores de condutividade abaixo de 100 μ S cm $^{-1}$. É importante ressaltar que os valores de condutividade podem variar devido às condições climáticas ocorridas em períodos de chuva e seca (ALVARENGA et al., 2012; MARMONTEL e RODRIGUES, 2015).

As variações observadas entre os dados de outubro/2019 e maio/2020 podem ser atribuídas às diferenças entre o período de estiagem e de chuva, respectivamente. De acordo com a base de dados do Instituto Nacional de Meteorologia (INMET), os dados de precipitação acumulada apontam 20mm (4 de julho a 4 a outubro de 2019) no qual o reservatório possuía um volume útil de menos de 60% de sua capacidade (CEMADEN, 2019). Entretanto, para o campo de maio, os valores de precipitação acumulada no trimestre até a data da coleta foram de 212mm e o reservatório apresentava quase 100% de sua capacidade (CEMADEN, 2020).

De uma forma geral, a redução do volume do reservatório em períodos de seca pode provocar o aumento das concentrações de matéria orgânica e nutrientes em função da redução do fator de diluição e isso pode contribuir para que a temperatura da água se eleve, reduzindo a dissolução de oxigênio na água (BARROSO; PINHEIRO; PEREIRA, 2018). Nesse sentido, ao longo da coleta realizada no mês de outubro, período no qual o reservatório apresentava volume inferior à campanha de maio, verificaram-se formações típicas de colônias algais na superfície da água, o que pode ter associação direta com a maior concentração OD e a variação de SDT detectados na água do reservatório nesse período.

Modelos de regressão múltipla e avaliação da acurácia

Os conjuntos de modelos de regressão múltipla foram criados utilizando a abordagem Stepwise bidirecional híbrida. As Tabelas 2 e 3 apresentam as bandas espectrais utilizadas e descrevem as equações resultantes dos modelos de regressão da primeira e segunda campanhas, respectivamente.

Tabela 2 - Equações de regressão de modelos de qualidade da água para Sentinel-2 e Landsat-8 (04/10/2019).

Sentinel-2/MSI		
Variável dependente	Equação	r ²
CE	-144,80 + (-2472,14 * B1) + (7325,98 * B2) + (-2567,43 * B3) + (-1486,76 * B8)	0,76
SDT	49,420 + (-255,040 * B1) + (277,272 * B3) + (-1188,427 * B4) + (1458,765 * B5) + (818,733 * B6) + (-1655,059 * B7) + (2286,197 * B8) + (-1857,481 * B8A) + (-436,163 * B11)	0,89
OD	8,9055 + (-129,5866 * B2) + (192,3651 * B4) + (36,4049 * B6) + (-116,7094 * B11)	0,83

Landsat-8/OLI		
Variável dependente	Equação	r ²
CE	-108,62 + (-7534,79 * B1) + (11877,90 * B2) + (-2931,28 * B3) + (-901,26 + B5)	0,69
SDT	50,373 + (-889,178 * B1) + (621,919 * B2) + (58,560 * B3) + (-136,898 * B4) + (716,833 * B5) + (-446,931 * B6) + (-1201,418 * B7)	0,50
OD	9,5867 + (-127,1909 * B2) + (115,4625 * B4) + (-223,5492 * B6) + (227,0583 * B7)	0,69

Fonte - Adaptado de Pizani et al. (2020).

Tabela 3 - Equações de regressão de modelos de qualidade da água para Sentinel-2 e Landsat-8 (31/05/2020).

Sentinel-2/MSI		
Variável dependente	Equação	r ²
CE	82,212 + (-460,016 * B1) + (-1097,112 * B2) + (965,785 * B3) + (-740,767 * B5)	0,78
SDT	49,420 + (-255,040 * B1) + (277,272 * B3) + (-1188,427 * B4) + (1458,765 * B5) + (818,733 * B6) + (-1655,059 * B7) + (2286,197 * B8) + (-1857,481 * B8A) + (-436,163 * B11)	0,71
OD	7,9184 + (-119,2066 * B2) + (-48,3723 * B4) + (587,0485 * B6) + (-589,1092 * B11)	0,81

Landsat-8/OLI		
Variável dependente	Equação	r ²
CE	75,343 + (-2202,091 * B1) + (2143,740 * B2) + (-383,852 * B3) + (521,453 * B5)	0,62
SDT	50,373 + (-889,178 * B1) + (621,919 * B2) + (58,560 * B3) + (-136,898 * B4) + (716,833 * B5) + (-446,931 * B6) + (-1201,418 * B7)	0,50
OD	10,025 + (-108,454 * B2) + (48,636 * B4) + (-888,292 * B6) + (500,713 * B7)	0,49

Fonte - Adaptado de Pizani et al. (2020).

A aplicação dos modelos de regressão múltipla utilizados em outubro/2019 para os parâmetros NOA da campanha realizada em maio/2020 produziu altos coeficientes de determinação (r^2) para o instrumento MSI do satélite Sentinel-2, variando de 0,71 a 0,81. Este resultado prova que a aplicação do modelo desenvolvido para a primeira campanha com o uso dos produtos MSI obteve sucesso ao ser reaplicado na segunda campanha, considerando um período diferente do ano e outras condições encontradas no reservatório.

Os resultados obtidos aplicando aos modelos as bandas espectrais do sensor OLI/Landsat-8 não foram tão satisfatórios se comparados aos resultados do MSI/Sentinel-2, porém foram coerentes com os produtos obtidos na primeira campanha. Em outubro/2019, os índices de r^2 para CE, SDT e OD foram de 0,69, 0,50 e 0,69, respectivamente. Os mesmos modelos indicaram valores para CE, SDT e OD de 0,62, 0,50 e 0,49, respectivamente.

Considerando esses coeficientes, é possível afirmar que o sensor MSI produziu melhores resultados que o sensor OLI para os três modelos aplicados para estimativa dos parâmetros NOA. O estudo de Pizani et al. (2020) também apresenta para o sensor MSI melhores resultados quando aplicados os modelos aos parâmetros opticamente ativos. Este estudo supõe que o maior número de bandas espectrais encontrados no sensor MSI, além da resolução espectral mais fina das bandas 3-7 e 8A, provavelmente explicaria os valores obtidos. Considera-se também que, além da resolução espectral, a resolução radiométrica (assim como a calibração radiométrica) das cenas de cada sensor possa ser um fator diferencial para a influência direta nos resultados. Como o sensor OLI apresentou resultados inferiores comparados ao sensor MSI em ambos os estudos, é de interesse destes autores desenvolver, futuramente, um modelo específico para o sensor OLI de forma a aprimorar os resultados provenientes deste instrumento.

Dada a coerência encontrada nos resultados da segunda campanha, é possível afirmar que os modelos produzidos na primeira campanha se adequaram satisfatoriamente e conseguiram estimar de forma apropriada os parâmetros NOA aqui estudados. A Tabela 4 apresenta as métricas de precisão utilizadas para avaliar os modelos. Observa-se que os valores de p para SDT ficaram acima de 0,05 ($p\text{-value} > 0,05$). No entanto, este resultado pode ser considerado aceitável, uma vez que o método Stepwise permite flexibilidade ao valor atribuído a p (BABYAK, 2004). Os valores MAE (erro médio absoluto ou *mean absolute error*) e RMSE (erro médio quadrático ou *root mean square error*) mostram a mesma tendência nos valores.

Tabela 4 - Métricas de avaliação para os modelos empregados.

Sentinel-2/MSI									
	04/10/2019				31/05/2020				
Parâmetro	r^2	MAE	RMSE	$p\text{-value}$	r^2	MAE	RMSE	$p\text{-value}$	
CE	0,76	3,70	4,87	0,01	0,78	0,68	0,88	< 0,01	
SDT	0,89	< LD	12,3	0,03	0,71	0,31	0,39	0,12	
OD	0,83	0,06	0,08	< 0,01	0,81	0,13	0,17	< 0,01	

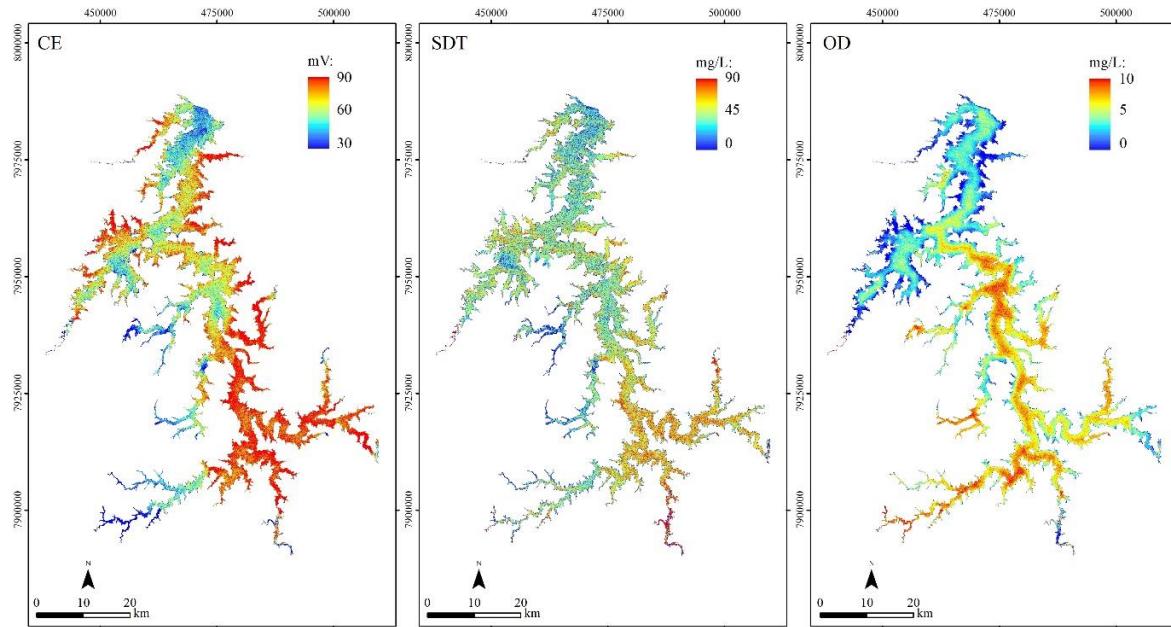
Landsat-8/OLI									
	04/11/2019				31/05/2020				
Parâmetro	r^2	MAE	RMSE	$p\text{-value}$	r^2	MAE	RMSE	$p\text{-value}$	
CE	0,69	4,76	5,59	0,03	0,62	0,88	1,17	0,01	
SDT	0,50	< LD	34,18	0,14	0,50	0,53	0,68	0,14	
OD	0,69	0,08	0,11	0,03	0,49	0,20	0,28	0,04	

* LD = Limite de detecção

Fonte - Elaborado pelos autores (2021).

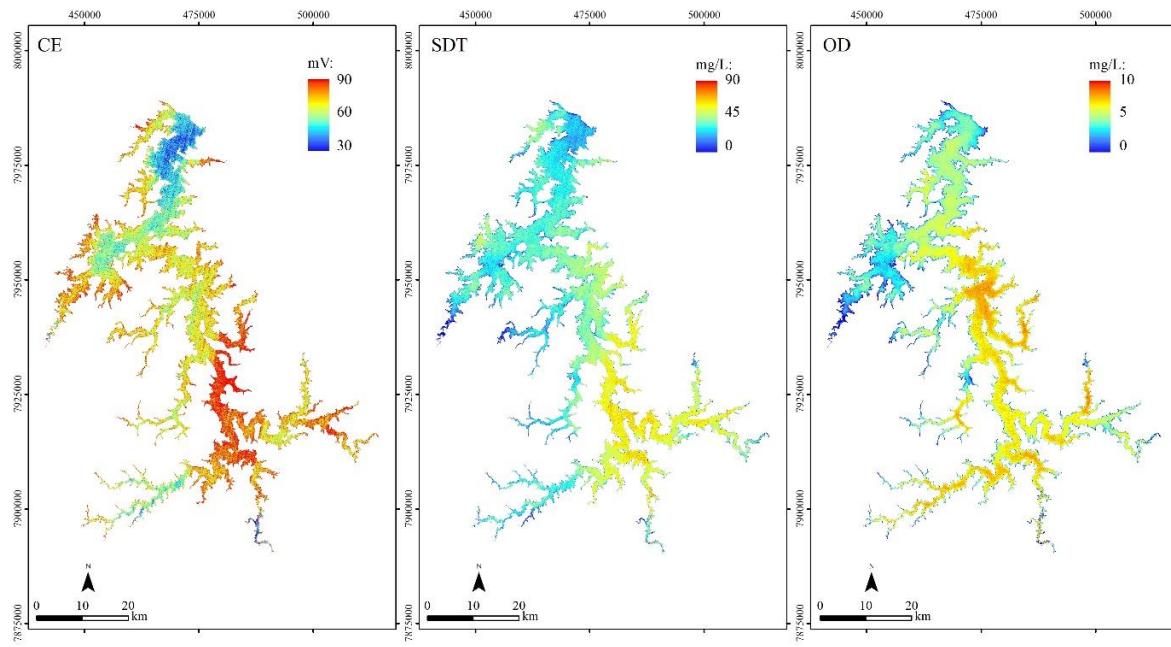
As Figuras 4 e 5 ilustram os mapas que foram gerados para os modelos de CE, SDT e OD com o uso dos sensores MSI e OLI, respectivamente.

Figura 4 - Mapas produzidos usando os modelos de CE, SDT e OD para o sensor MSI/Sentinel-2.



Fonte - Elaborado pelos autores (2021).

Figura 5 - Mapas produzidos usando os modelos de CE, SDT e OD para o sensor OLI/Landsat-8.



Fonte - Elaborado pelos autores (2021).

CONSIDERAÇÕES FINAIS

A aplicação do modelo empírico desenvolvido em outubro de 2019 para dados de maio de 2020 confirmou sua replicabilidade permitindo a estimativa dos parâmetros não-opticamente ativos (NOA) em um mesmo

reservatório, porém em épocas diferentes. Esta pesquisa revelou que a reaplicação dos modelos gerados possibilita determinar os parâmetros de condutividade elétrica (CE), sólidos dissolvidos totais (SDT) e oxigênio dissolvido (OD).

Cabe ressaltar que o Reservatório de Três Marias apresenta boa qualidade de água, o que resulta em baixas alterações dos parâmetros ao longo do percurso. O estado da água, em geral, altamente clara, pode dificultar a estimativa da qualidade dos parâmetros opticamente ativos (OA) por sensoriamento remoto (uma vez que estes constituintes são registrados devido às suas propriedades ópticas). Dessa forma, este obstáculo pode tornar ainda mais complexa a estimativa dos NOA que são inferidos indiretamente a partir dos componentes OA.

Outra possível limitação de modelos empíricos desenvolvidos para águas continentais complexas se caracteriza por, frequentemente, não serem replicáveis em outras áreas de estudo devido à grande variação da concentração dos componentes de uma região para a outra. Em geral, os algoritmos devem ser calibrados localmente, o que torna desaconselhável comparações de concentrações medidas por sensoriamento remoto em outras áreas.

No entanto, ferramentas estatísticas como a regressão múltipla para estimar de dados *in situ* e de sensores podem ser poderosos mecanismos de análise aplicados ao sensoriamento remoto aquático. As informações obtidas podem fornecer subsídio no planejamento, auxiliando a gestão pública e privada no monitoramento em ambientes represados.

Durante os meses observados, a condição da água do reservatório, no geral, se apresentou muito homogênea, fato que revela a boa qualidade do ambiente aquático denotando baixíssimos índices de concentração dos componentes estudados. Pretende-se continuar monitorando o estado da água e, futuramente, realizar novas coletas aplicando os modelos de regressão múltipla de forma a tornar o conjunto de dados e, consequentemente, o modelo mais robusto.

AGRADECIMENTOS

Este trabalho foi produzido no âmbito de um projeto mais amplo intitulado “Monitoramento Inteligente da Qualidade da Água em Reservatórios Hidrelétricos Através do Desenvolvimento de um Algoritmo Fotogramétrico” e financiado pela Companhia Energética de Minas Gerais (CEMIG, projeto GT-0607). Os autores são gratos à equipe GT-0607 que tornou este artigo possível.

REFERÊNCIAS

ABDELMALIK, K. Role of statistical remote sensing for inland water quality parameters prediction. **The Egiptian Journal of Remote Sensing and Space Science**, v.21, n.2, p.193-200, 2018.
<https://doi.org/10.1016/j.ejrs.2016.12.002>

ALPARSLAN, E.; COSKUN, H.; ALGANCI, U. Water quality determination of Küçükçekmece Lake, Turkey by using multispectral satellite data. **The Scientific World Journal**, v.9, p.1215-1229, 2009.
<https://doi.org/10.1100/tsw.2009.135>

ALVARENGA, L. A.; MARTINS, M.; CUARTAS, L.; PENTEADO, V.; ANDRADE, A. Estudo da qualidade e quantidade da água em microbacia, afluente do rio Paraíba do Sul – São Paulo, após ações de preservação ambiental. **Revista Ambiente & Água**, v.7, n.3, p. 228-240, 2012.
<https://doi.org/10.4136/ambi-agua.987>

APHA – American Public Health Association. **Standard methods for the examination of water and wastewater**. Washington: American Public Health Association, American Water Works Association, Water Environment Federation, 2012.

ARTO, I.; ANDREONI, V.; RUEDA-CANTUCHE, J.M. Global use of water resources: A multiregional analysis of water use, water footprint and water trade balance. **Water Resources and Economics**, v.15, p.1-14, 2016.

AVDAN, Z.; KAPLAN, G.; GONCU, S.; AVDAN, U. Monitoring the water quality of small water bodies using high-resolution remote sensing data. **ISPRS International Journal of Geo-Information**, v.8, n.12, p.553, 2019. <https://doi.org/10.3390/ijgi8120553>

BABYAK, M. What you see may not be what you get: a brief, nontechnical introduction to overfitting in regression-type models. **Psychosomatic Medicine**, v.66, n.3, p.411-421, 2004.

<https://doi.org/10.1097/00006842-200405000-00021>

BARBOSA, C.; NOVO, E.; MARTINS, V. (Ed.) **Introdução ao sensoriamento remoto de sistemas aquáticos**: princípios e aplicações. 1 ed. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2019.

BARROSO, G.; PINHEIRO, W.; PEREIRA, A. Avaliação da qualidade da água do reservatório da Usina Hidrelétrica de Nova Ponte (MG) e sua relação com o volume de água do reservatório. **Revista Geográfica Acadêmica**, v.12, n.2, p.91-109, 2018.

BLANCHON, D. **Atlas mondial de l'eau: de l'eau pour tous?** 1 ed. Paris: Editions Autrement, 2009.

BRASIL (Ministério do Meio Ambiente). **Resolução CONAMA nº 357, de 15 de junho de 2005**. Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes, e dá outras providências. Disponível em: <http://www.mma.gov.br/port/conama/legiabre.cfm?codlegi=459>. Acesso em: 30 jun. 2020.

CACHAPUZ, P. **Usinas da CEMIG**: a história da eletricidade em Minas e no Brasil, 1952 – 2005. 1 ed. Rio de Janeiro: Centro da Memória da Eletricidade no Brasil, 2006.

CEMADEN – Centro Nacional de Monitoramento e Alertas de Desastres Naturais. **Situação atual e projeção hidrológica para Reservatório Três Marias** – Bacia do Rio São Francisco. Boletim 10/2019. 2019. Disponível em: http://www.cemaden.gov.br/wp-content/uploads/2019/10/Relatorio_AproveitamentoTre%C3%82sMarias_2019_setembro_final-1.pdf. Acesso em: 01 mar. 2021

CEMADEN – Centro Nacional de Monitoramento e Alertas de Desastres Naturais. **Situação atual e projeção hidrológica para Reservatório Três Marias** – Bacia do Rio São Francisco. Boletim 06/2020. 2020. Disponível em: http://www.cemaden.gov.br/wp-content/uploads/2020/06/Relatorio_AproveitamentoTr%C3%A3sMarias_2020_MAIO_KDL_AC_LB.pdf. Acesso em: 01 mar. 2021.

CETESB – Companhia Ambiental do Estado de São Paulo. **Relatório de Qualidade das Águas Inteiros do Estado de São Paulo**. Apêndice E: Significado ambiental e sanitário das variáveis de qualidade das águas e dos sedimentos e metodologias analíticas e de amostragem. 2019. Disponível em: <https://cetesb.sp.gov.br/aguas-inteiros/wp-content/uploads/sites/12/2020/09/Apendice-E-Significado-Ambiental-e-Sanitario-das-variaveis.pdf>. Acesso em: 05 mar. 2021.

CHEN, J.; ZHU, W.; TIAN, Y.; YU, Q. Estimation of colored dissolved organic matter from Landsat-8 imagery for complex inland water: case study of Lake Huron. **IEEE Transactions on Geoscience and Remote Sensing**, v.55, n.4, p.2201-2212, 2017. <https://doi.org/10.1109/TGRS.2016.2638828>

CIONEK, V.; ALVES, G.; TÓFOLI, R.; RODRIGUES-FILHO, J.; DIAS, R. Brazil in the mud again: lessons not learned from Mariana dam collapse. **Biodiversity and Conservation**, v.28, n.7, p.1935-1938, 2019.

CNES – Centre National d'Etudes Spatiales. **OTB**: Software. Versão 7.1. [S.I.]: CNES, 2020.

CURTARELLI, V.; BARBOSA, C.; MACIEL, D.; FLORES JÚNIOR, R.; CARLOS, F.; NOVO, E.; CURTARELLI, M.; SILVA, E. Diffuse Attenuation of Clear Water Tropical Reservoir: A Remote Sensing Semi-Analytical Approach. **Remote Sensing**, v.12, p.1-23, 2020. <https://doi.org/10.3390/rs12172828>

ESRI – Environmental Systems Research Institute. **ArcGIS for desktop**: Software. Versão 10.3. [S.I.]: ESRI, 2014.

GHOLIZADEH, M.; MELESSE, A.; REDDI, L. A comprehensive review on water quality parameters estimation using remote sensing techniques. **Sensors**, v.16, n.8, p.1298, 2016.
<https://doi.org/10.3390/s16081298>

HADJIMITSIS, D.; CLAYTON, C. Field spectroscopy for assisting water quality monitoring and assessment in water treatment reservoirs using atmospheric corrected satellite remotely sensed imagery. **Remote Sensing**, v.3, n.2, p.362-377, 2011.

HUO, A.; ZHANG, J.; QIAO, C.; LI, C.; XIE, J.; WANG, J.; ZHANG, X. Multispectral remote sensing inversion for city landscape water eutrophication based on Genetic Algorithm-Support Vector Machine. **Water Quality Research Journal of Canada**, v.49, n.3, p.285-293, 2014.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Base cartográfica:** malhas territoriais. 2010. Disponível em: <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>. Acesso em: 01 jun. 2021.

IGAM – Instituto Mineiro de Gestão das Águas. **Base cartográfica:** hidrografia. 2012. Disponível em: <http://www.igam.mg.gov.br/component/content/105?task=view>. Acesso em: 01 jun. 2021.

JIANG, G.; LIU, D.; SONG, K.; WANG, Z.; ZHANG, B.; WANG, Y. Application of multivariate model based on three simulated sensors for water quality variables estimation in Shitoukoumen Reservoir, Jilin Province, China. **Chinese Geographical Science**, v.20, n.4, p.337-344, 2010.

LONJOU, V.; DESJARDINS, C.; HAGOLLE, O.; PETRUCCI, B.; TREMAS, T.; DEJUS, M.; MAKARAU, A.; AUER, S. MACCS-ATCOR joint algorithm (MAJA). **Remote Sensing of Clouds and the Atmosphere XXI**, v. 10001, p.1-13, 2016.

LI, X.; HUANG, M.; WANG, R. Numerical simulation of Donghu Lake hydrodynamics and water quality based on remote sensing and MIKE 21. **ISPRS International Journal of Geo-Information**, Switzerland, v.9, n.2, p.94, 2020.

LIU, J.; ZHANG, Y.; YUAN, D.; SONG, X. Empirical estimation of total nitrogen and total phosphorus concentration of urban water bodies in China using high resolution IKONOS multispectral imagery. **Water**, Switzerland, v.7, n.11, p.6551-6573, 2015. <https://doi.org/10.3390/w7116551>

MARMONTEL, C. V. F.; RODRIGUES, V. A. Parâmetros indicativos para qualidade da água em nascentes com diferentes coberturas de terra e conservação da vegetação ciliar. **Floresta e Ambiente**, v.22, n.2, p.171-181, 2015. <https://doi.org/10.1590/2179-8087.082014>

MCCOY, R. **Field methods in remote sensing**. 1 ed. New York: Guilford Press, 2005.

MCFEETERS. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, London, v.17, n.7, p.1425-1432, 1996. <https://doi.org/10.1080/01431169608948714>

MERTES, L.; DEKKER, A.; BRAKENRIDGE, G.; BIRKETT, C.; LETOURNOU, G. Rivers and lakes. In: USTIN, S. (Ed.) **Manual of remote sensing**: remote sensing for natural resource management and environmental monitoring. New York: John Wiley & Son, 2004. p.345-400.

MINAS GERAIS (Estado). **Deliberação Normativa Conjunta COPAM/CERH nº 01/2008**. Disponível em: <http://www.compe.org.br/estadual/deliberacoes/conjunta/1-2008.pdf>. Acesso em: 01 mar. 2021.

PEPS – Plateforme d’Exploitation des Produits Sentinel. **French Access to the Sentinel Products**. 2020. Disponível em: <https://peps.cnes.fr/rocket/#/home>. Acesso em: 06 jun. 2020.

PEREIRA, G.; LOHMANN, M.; MAGANHOTTO, R. Proposta e avaliação de índices para delimitar e mapear corpos d’água utilizando imagens do satélite LANDSAT 8. **Revista Brasileira de Geografia Física**, Recife, v.9, n.6, p.1956-1968, 2016.

PIZANI, F.; MAILLARD, P.; FERREIRA, A.; AMORIM, C. Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors. **ISPRS Annals of the Photogrammetry Remote Sensing and Spatial Information Sciences**, Nice, v.V-3-2020, p.401-408, 2020.

PU, F.; DING, C.; CHAO, Z.; YU, Y.; XU, X. Water-quality classification of inland lakes using Landsat8 images by Convolutional Neural Networks. **Remote Sensing**, Switzerland, v.11, n.14, p.1674, 2019. <https://doi.org/10.3390/rs11141674>

R CORE TEAM. **R**: A language and environment for statistical computing. Software. RStudio Versão 1.5.5019. 2020. Vienna, Austria. Disponível em: <https://www.R-project.org>. Acesso em: 06 jun. 2020.

THOMPSON, F.; OLIVEIRA, B.; CORDEIRO, M.; MAIS, B.; RANGEL, T.; PAZ, P.; FREITAS, T.; LOPES, G.; SILVA, B.; CABRAL, A.; SOARES, M.; LACERDA, D.; VERGILIO, C.; LOPES-FERREIRA, M.; LIMA, C.; THOMPSON, C.; REZENDE, C. Severe impacts of the Brumadinho dam failure (Minas Gerais, Brazil) on the water quality of the Paraopeba River. **Science of the Total Environment**, v.705, p.135914, 2020.

TOMING, K.; KUTSER, T.; LAAS, A.; SEPP, M.; PAAVEL, B.; NÔGES, T. First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. **Remote Sensing**, Switzerland, v.8, n.8, p.640, 2016.

TOPP, S.; PAVELSKY, T.; JENSEN, D.; SIMARD, M.; ROSS, M. Research trends in the use of remote sensing for inland water quality science: moving towards multidisciplinary applications. **Water**, Switzerland, v.12, n.1, p.169, 2020. <https://doi.org/10.3390/w12010169>

TU, M.; SMITH, P.; FILIPPI, A. Hybrid forward-selection method-based water-quality estimation via combining Landsat TM, ETM+, and OLI/TIRS images and ancillary environmental data. **PLoS ONE**, San Francisco, v.13, n.7, 2018. <https://doi.org/10.1371/journal.pone.0201255>

UNESCO-WAPP – United Nations Educational, Scientific and Cultural Organization – World Water Assessment Programme. **Water, a shared responsibility**. 2006. Disponível em: <http://www.unesco.org/new/en/natural-sciences/environment/water/wwap/wwdr/wwdr2-2006/downloads-wwdr2>. Acesso em: 09 jun. 2020.

USGS – United States Geological Survey. **Land Surface Reflectance Code (LASRC) Product Guide**. Sioux Falls: USGS, 2018. Disponível em: <https://www.usgs.gov/media/files/landsat-8-collection-1-land-surface-reflectance-code-product-guide>. Acesso em: 27 jan. 2020.

USGS – United States Geological Survey. **Earth Explorer**. 2020. Disponível em: <https://earthexplorer.usgs.gov/>. Acesso em: 20 dez. 2019.

VERGILIO, C.; LACERDA, D.; OLIVEIRA, B.; SARTORI, E.; CAMPOS, G.; PEREIRA, A.; AGUIAR, D.; SOUZA, T.; ALMEIDA, M.; THOMPSON, F.; REZENDE, C. Metal concentrations and biological effects from one of the largest mining disasters in the world (Brumadinho, Minas Gerais, Brazil). **Scientific Reports**, v.10, n.1, p.5936, 2020. <https://doi.org/10.1038/s41598-020-62700-w>

VON SPERLING, E. **Morfologia de lagos e represas**. 1 ed. Belo Horizonte: DESA/UFGM, 1999.

VON SPERLING, M. **Introdução à qualidade das águas e ao tratamento de esgotos**. 4 ed. Belo Horizonte: DESA/UFGM, 2007.

WANG, D.; KAGEYAMA, Y.; NISHIDA, M.; SHIRAI, H. Algorithm to analyze water quality conditions of Lake Hachiroko using textures of JERS-1 SAR data. **International Journal of the Society of Materials Engineering for Resources**, Akita, v.18, n.2, p.51-58, 2012. <https://doi.org/10.5188/ijsmr.18.51>

WANG, D.; KAGEYAMA, Y.; NISHIDA, M.; SHIRAI, H.; KASAI, C. Water quality analysis of Lake Hachiroko, Japan, using ALOS PALSAR data. **International Journal of the Society of Materials Engineering for Resources**, Akita, v.20, n.2, p.175-180, 2014. <https://doi.org/10.5188/ijsmr.20.175>

XIANG, B.; SONG, J.; WANG, X.; ZHEN, J. Improving the accuracy of estimation of eutrophication state index using a remote sensing data-driven method: a case study of Chaohu Lake, China. **Water SA**, v.41, n.5, p.753-761, 2015. <https://doi.org/10.4314/wsa.v41i5.18>

XIONG, J.; LIN, C.; MA, R.; CAO, Z. Remote sensing estimation of lake total phosphorus concentration based on MODIS: a case study of Lake Hongze. **Remote Sensing**, Switzerland, v.11, n.17, p.2068, 2019. <https://doi.org/10.3390/rs11172068>

Recebido em: 10/06/2021

Aceito para publicação em: 03/11/2021

ANEXO E – Artigo: The estimation of water quality parameters in lentic environments through remote sensing technologies: a review of the past two decades

PIZANI, F.M.C.; MAILLARD, P.; AMORIM, C.C.. The estimation of water quality parameters in lentic environments through remote sensing technologies: a review of the past two decades. Revista Brasileira de Cartografia (RBC. Online), v. 74, p. 729-754, 2022.



The Estimation of Water Quality Parameters in Lentic Environments Through Remote Sensing Technologies: a Review of the Past Two Decades

Estimativa de Parâmetros de Qualidade da Água em Ambientes Lênticos Por Meio de Tecnologias de Sensoriamento Remoto: uma Revisão das Últimas Duas Décadas

Fernanda Mara Coelho Pizani ¹, Philippe Maillard ² e Camila Costa Amorim ³

¹ Federal University of Minas Gerais, Belo Horizonte, Brazil. fm.coelho@yahoo.com.br

ORCID: <https://orcid.org/0000-0001-8841-8193>

² Federal University of Minas Gerais, Belo Horizonte, Brazil. philippermaillard@yahoo.com.br

ORCID: <https://orcid.org/0000-0003-3405-5096>

³ Federal University of Minas Gerais, Belo Horizonte, Brazil. camila@desa.ufmg.br

ORCID: <https://orcid.org/0000-0001-6132-0866>

Received: 04.2022 | Accepted: 06.2022

Abstract: The use of remote sensing technology applied to measure the quality of continental waters has grown exponentially since the turn of the century. Using different sensors on board satellites or airborne platforms, the estimation of water quality parameters has been carried out through both empirical and analytical approaches. This work aims to review the specific scientific production of the last two decades to assess how the evolution of the sensors and platforms have affected the potential and the limitations of remote sensing technologies to estimate water quality parameters in lakes and reservoirs. The study also focuses on the accuracy of remote sensing techniques for the major optically active parameters: chlorophyll-a and phycocyanin, Secchi disk depth and turbidity. The article is subdivided by sections dedicated to each of these parameters. A review of remote sensing platforms and sensors precedes the parameters sections. The past 20 years have brought a large body of articles on how remote sensing data can be used to estimate these parameters. Empirical methods dominate overwhelmingly with a four to one proportion over analytical approaches. Environmental factors such as season, complexity of water and concentration loads appear to exert a strong control over the quality of the results. Recent platforms and sensors have brought noticeable improvements over results achieved in this period.

Keywords: Water Quality. Optical Sensors. Satellite Missions. Empirical Models. Analytical Models.

Resumo: O uso da tecnologia de sensoriamento remoto aplicada para mensurar a qualidade das águas continentais tem crescido exponencialmente desde a virada do século. Usando diferentes sensores a bordo de satélites ou plataformas aéreas, a estimativa dos parâmetros de qualidade da água vem sendo realizada por meio de abordagens empíricas e analíticas. Este trabalho visa revisar a produção científica específica das últimas duas décadas para avaliar como a evolução dos sensores e plataformas afetaram o potencial e as limitações das tecnologias de sensoriamento remoto para estimar parâmetros de qualidade da água em lagos e reservatórios. O estudo também se concentra na precisão das técnicas de sensoriamento remoto para os principais parâmetros opticamente ativos: clorofila-a e ficocianina, profundidade do disco de Secchi e turbidez. O artigo está subdividido em seções dedicadas a cada um desses parâmetros. Uma revisão das plataformas e sensores de sensoriamento remoto precede as seções de parâmetros. Os últimos 20 anos trouxeram uma grande quantidade de artigos sobre como os dados de sensoriamento remoto podem ser usados para estimar esses parâmetros. Os métodos empíricos predominam com uma proporção de quatro para um sobre as abordagens analíticas. Fatores ambientais como estação do ano, complexidade das cargas de água e concentração parecem exercer um forte controle sobre a qualidade dos resultados. Plataformas e sensores recentes trouxeram melhorias notáveis em relação aos resultados alcançados neste período.

Palavras-chave: Qualidade da Água. Sensores Ópticos. Missões de Satélites. Modelos Empíricos. Modelos Analíticos.

1 INTRODUÇÃO

Monitoring water quality (WQ) in aquatic lentic environments is critical for the proper management of

water resources and to guarantee a sustainable use. It is also a means to get an insight on the dynamics of the surrounding human activities (ODERMATT et al., 2008). The quality of these environments can be determined through their physical, chemical and biological characteristics which will be addressed as WQ “parameters”.

There are hundreds of parameters that can attest the quality of water. Some of the most common parameters that can be monitored remotely are chlorophyll-a (chl-a), transparency, turbidity and total suspended matters (TSM) (AVDAN et al., 2019). In addition to these parameters, remote sensing has been used to estimate coloured dissolved organic matter (CDOM), phycocyanin (PC), true colour and temperature. Other non-optically active parameters can also be inferred indirectly through their relationship with the optically active ones: total phosphorous (TP) (XIONG et al., 2019), total nitrogen (TN) (LIU et al., 2015), pH, chemical oxygen demand (COD) and dissolved oxygen (DO) (WANG et al., 2012; WANG et al., 2014; PU et al., 2019). Time series of satellite images have also been used to monitor surface water temperature (ALCÂNTARA et al., 2011; CURTARELLI et al., 2014; LUZ; GUASSELLI; ROCHA, 2017), an important parameter not only for WQ but also as a means to monitor climatic changes (LI et al., 2017).

Much of the literature on the topic of remote sensing applied to WQ can be found in periodical articles from the past forty years with a few books also dedicated to the subject. Liu, Islam and Gao (2003) did an extensive review on the subject going as far back as 1981 and covering up until the year 2000. Since then, there has been an increased number of publications in these past two decades boosted by the emergence of a large number of new satellite missions with better spectral and spatial resolution and by the explosion of the number of accessible unmanned aerial vehicles (UAV), drones and small high performance multispectral and hyperspectral cameras. These new platforms and sensors have received much attention as means to acquire WQ estimates remotely.

Remote sensing applied to WQ has been investigated by a variety of scientific communities such as hydrology (POTES; COSTA; SALGADO, 2012; CURTARELLI et al., 2014; BONANSEA et al., 2015; HANSEN; WILLIAMS, 2018), hydrobiology (ZHANG et al., 2016; BRESCIANI et al., 2018), public health (TORBICK et al., 2014; VAN DER MERWE; PRICE, 2015; TORBICK et al., 2018), urban planning (HUO et al., 2014; LIU et al., 2015) and applied statistics (WILKIE et al., 2019; LI; HUANG; WANG, 2020), amongst others. Whatever the application or the purpose, most authors have brought forward the relative ease and low cost of remote sensing methods over traditional in situ methods (BONANSEA et al., 2015; ABDELMALIK, 2018; AVDAN et al., 2019). Furthermore, it has been reported that these traditional approaches often use a relatively small number of samples and at an insufficient frequency (WILKIE et al., 2019). Within that context, remote sensing can bring a comprehensive distributed estimate of some important WQ parameters (STEOFOLI; CHAROU, 2012) even considering some important limitations like the restriction to the surface layer and several other uncontrolled factors affecting the optical properties of water like the atmospheric conditions at the moment of acquisition and the interference of the air-water interface (for a review, see Mertes et al. (2004)).

The advantages mentioned above are well recognized and have transformed remote sensing in a widely used tool for monitoring lakes and reservoirs. Lentic environments suffer constant threats mainly characterised by changes in water level, toxic pollution, salinization, eutrophication, acidification, sediment pollution and invasion from exotic species, which all contribute to the deterioration of the quality of water (ODERMATT et al., 2018). A wide range of approaches have been applied to this aim: empirical, semi-empirical, analytical and semi-analytical. Whereas empirical methods focus on establishing a statistical relationship between the values of some WQ parameter and the corresponding radiance or reflectance measured by optical sensors, analytical methods are based on radiative transfer equations to model how the physical properties of absorption and dispersion of light are altered by such parameter (VAN NGUYEN et al., 2020). Some approaches blend the two methods by incorporating prior knowledge (for instance by pre-selecting spectral bands) or by fine-tuning an analytical approach through some adjustment method (e.g., regression, root mean square error).

Other empirical approaches include machine learning (HUO et al., 2014; RUESCAS et al., 2018; KUPSSINKU et al., 2020; PAHLEVAN et al., 2020) and artificial neural network (ANN) (FERREIRA; GALO, 2013; VERONEZ et al., 2018; PU et al., 2019) that showed good potential for estimating chl-a and CDOM. Ha et al. (2017) successfully used ANN to determine the level of eutrophication in lakes. It is within the context of reporting the advancements achieved in the past two decades in terms of platforms, sensors and

data processing that this article has been prepared. Firstly, we present an overview of the remote sensing instruments (sensors and platforms) used to monitor WQ, then we investigate each of the most common optically active WQ parameters and how remote sensing technology has been successfully used for their determination.

2 INSTRUMENTS USED IN AQUATIC REMOTE SENSING

Remote sensing applied to aquatic applications allows to make time series of observations about the quality of surface water of lakes, reservoirs and rivers and their dynamics (ZHANG et al., 2016). Some remote sensing platforms and instruments also allow to assess the quantity of water through altimetry sensors (ROSMORDUC et al., 2018) but this aspect will not be treated here. The effectiveness of the application of remote sensing to estimate WQ depends on the choice of appropriate platforms and instruments for this purpose. Optical sensors measure the amount of electromagnetic radiation at different wavelengths reflected by the aquatic surface. The data are usually converted in radiance or reflectance before being used to estimate WQ parameters (ALPARSLAN; COSKUN; ALGANCI, 2009). In particular, the reflectance measurements (which are independent from the amount of illumination) are fundamental for the generation of WQ models based on remote sensing (LI et al., 2020).

The past twenty years (2000 – 2020) have been marked by the development of new instruments (platforms and sensors) capable of improved measurement estimates of surface or near-surface WQ parameters, some of which were specifically designed for such purpose. Advances in these sensors include finer spectral, spatial and radiometric resolutions, shorter revisit time, increased number of satellite constellations, and the possibility of free and easily retrieved data. The scientific community has proven the effectiveness of using these sensors for the evaluation of various processes including many environmental parameters (ALPARSLAN; COSKUN; ALGANCI, 2010). Estimates of WQ in lentic environments by remote sensing can be performed at local, regional, continental or global scales (see Politi, Cutler and Rowan (2015)). Depending on the research objective, one can choose from a broad variety of platforms (Table 1).

Satellite images covering the visible and infrared spectral regions present a discretised brightness signal that combines the radiance of the surface and the interference of the atmosphere between the surface and the sensor. Pre-processing is then required to reduce the effect of the atmosphere on the data (ABDELMALIK, 2018). Molecules in the atmosphere and aerosols absorb and scatter both the incoming solar radiation and outgoing radiance reflected by the Earth's surface and alter the signal that reaches the sensor, a process generally called atmospheric attenuation (ANSPER; ALIKAS, 2019). The process of atmospheric attenuation is well understood today and a wealth of algorithms are available to correct these effects on the different satellite sensors for which many review articles are available (SOLA et al., 2018; ZHANG et al., 2018; DOXANI et al., 2018; MISHRA et al., 2020). The most sophisticated of these algorithms use complementary information (often from other satellites or meteorological models) such as aerosol thickness, water vapour and digital elevation models to improve the correction. Some sensors have incorporated specific bands like the “coastal / aerosol”, “water vapour” and “cirrus” bands (bands 1, 9 and 10) of the Sentinel-2 multispectral Instrument (MSI) in order to improve atmospheric correction.

Most moderate and high spatial resolution satellite images are freely available through satellite agencies like the United States Geological Survey (USGS) Earth Explorer (<https://earthexplorer.usgs.gov/>) or the European Space Agency/Copernicus' Copernicus Open Access Hub (<https://scihub.copernicus.eu/>). Very-high-resolution images can also be obtained from commercial satellites, but can be excessively expensive depending on the size of the area. In the case of models using in situ data conjugated with satellite image data it is highly recommended to match the field campaign with the passage of the satellite to ensure more accurate results and to avoid the effect of changes in the environmental conditions that could alter the WQ parameters (CHEN et al., 2016).

Table 1- Satellites and airborne vehicles sensors launched between 2000 and 2009 often used for WQ assessment²¹⁶
 Legend: AHS=Airborne Hyperspectral Scanner.

Platform/Sensor	Launch date	Spectral bands (nm)	Spatial resolution (m)	Temporal resolution (days)
EO-1/ALI	Nov 2000	6 VNIR (433-890); 1 Pan (480-690); 3 SWIR (1200-2350)	10-30	16
EO-1/Hyperion	Nov 2000	242 Hyperspectral bands: 49 VNIR (426-925); 147 SWIR (912-2395). 22 bands are not calibrated, have no valid values and are not included into Earth Engine assets	30	16
NOAA-16/AVHRR	Sep 2000	2 VNIR (580-1110); 1 SWIR (1580-1640); 1 MWIR (3550-3930); 2 TIR (10300-12500)	1100-4000	9
DigitalGlobe/ Quickbird	Oct 2001	4 VNIR (430-918); 1 Pan (450-900)	2.62-0.65	2.5
PROBA-1/CHRIS	Oct 2001	19 VNIR (400 - 1050)	18 - 36	7
AHS/CASI-1500	2002	288 Hyperspectral bands: VNIR (380-1050)	0.25-5	-
ENVISAT/AATSR	Mar 2002	3 VNIR (555-865); 1 SWIR (1600); 1 MWIR (3700); TIR (10850-12000)	1000	3-6
ENVISAT/MERIS	Mar 2002	15 VNIR (390-1040)	300-1200	3
SPOT-5/HRG	May 2002	3 VNIR (500-890); 1 Pan (480-710); 1 SWIR (1580-1750)	2.5 or 5-10-20	26
CBERS-2-2B/CCD, IRMSS, IRS and WFI	Oct 2003, Sep 2007	WFI: 2 VNIR (630-890) CCD: 1 Pan (510-730) 3 VNIR (450-890) IRMSS: 1 Pan (510-1100) 2 SWIR (1550-2350) 1 TIR (10400-12500)	20 80 or 160 2.7	5 26 (nadir) 3 (off-nadir) 26
CBERS-3-4/MUX, PAN, IRS and WFI	Dec 2013, Dec 2014	MUX: 4 VNIR (450-890) PAN: 1 Pan (510-850) 3 VNIR (520-890) IRS: 1 Pan (500-900) 2 SWIR (1550-2350) 1 TIR (10400-1250) WFI: 4 VNIR (450-890)	20 5 or 10 40 or 80 64	26 5 26 5
CBERS-04A/WPM, MUX and WFI	Dec 2019	WPM: 1 Pan (450-900) 4 VNIR (450-890) MUX: 4 VNIR (450-890) WFI: 4 VNIR (450-890)	2 or 8 16.5 55	31 31 5
CARTOSAT/Pan	May 2005	1 Pan (500-850)	2.5	5
ALOS/AVNIR-2	Jan 2006	4 VNIR (420-890); 1 Pan (520-770)	2.5-10	2
DigitalGlobe/ WorldView-1	Sep 2007	1 Pan	0.5	1.7

(To be continued)

(Conclusion)

Platform/Sensor	Launch date	Spectral bands (nm)	Spatial resolution (m)	Temporal resolution (days)
RapidEye/REIS	Aug 2008	5 VNIR (440-850)	5	1 (off-nadir) 5.5 (nadir)
HICO/International Space Station	Sep 2009	128 Hyperspectral bands: VNIR (350-1080)	100	10
DigitalGlobe/ WorldView-2	Oct 2009	8 VNIR (400-1040); 1 Pan (450-800)	1.85-0.46	1.1
COMS/GOCI	Jun 2010	8 VNIR (400-865)	500	10 image per day: 8 day, 2 night
GeoEye/GeoEye-1	Sep 2010	8 VNIR (450-920); 1 Pan (450-800)	1.65-0.41	< 3
AHS/APEX-ESA	2011	> 300 Hyperspectral bands: Default 114 VNIR (380-970); 199 SWIR (940-2500)	2-5	-
Suomi NPP/VIIRS	Oct 2011	5 bands (640-1145); 16 Moderate-res. bands (412-12013); 1 Day/Night band (500-900)	375-750	1-2 times a day
AHS/AVIRIS-NG	2012	425 Hyperspectral bands: (380-2510)	0.3-4	-
AHS/AisaFENIX	2013	620 Hyperspectral bands: VNIR (380-970); SWIR (970-2500)	1 m at 600 m altitude	-
Landsat-8/OLI and TIRS	Feb 2013	5 VNIR (430-880); 1 Pan (500-680); 2 SWIR (1570-2290); 1 Cirrus Cloud Detection (1360-1380); 2 TIR (10600-12510)	30-15-100	16
AHS/HySpex ODIN-1024	2014	427 Hyperspectral bands: VNIR (400-1000); SWIR (950-2500)	0.5 m at 2000 m altitude	-
NOAA/ WorldView-3	Aug 2014	8 VNIR (400-1040); 1 Pan (450-800); 8 SWIR (1195-2365)	1.24-3.7-0.31	1 - 4.5
Sentinel-2A-2B/MSI	Jun 2015, Mar 2017	8 VNIR (490-865); 2 SWIR (1610-2190); 3 atmospheric correction bands (443-1375)	10-20-60	10
Sentinel-3A-3B/OLCI	Feb 2016, Apr 2018	21 VNIR (400-1020)	300-1200	< 2.8
DigitalGlobe/ WorldView-4	Nov 2016	4 VNIR (655-920); 1 Pan (450-800)	0.3-1.24	1-4.5
PRISMA	2008– Latest: Mar 2019	238 Hyperspectral bands: 66 VNIR (400-1010); 1 Pan (400-700); 171 SWIR (920-2505)	5-30	29
GEO-KOMPSAT-2B/GOCI-II	Feb 2020	1 UV (370-390); VNIR (412-755); 1 Pan (845-885)	250	10 times a day

Source: Adapted from Gholizadeh et al. (2016).

Many recent multispectral and hyperspectral sensors were especially constructed for use in atmospheric platforms like aeroplanes, helicopters and UAVs. The latter have been widely popularised in recent years for remote sensing use, mostly fuelled by the availability of light weight sensors. The choice of platform is mostly dictated by the size of the area and the speed of the platform (VAN DER MERWE; PRICE, 2015). A variety of airborne sensors have been used for remote sensing of WQ, like the APEX, the MIVIS and the HySpex (PINARDI et al., 2015). These are still relatively large and heavy equipment and can only be carried by manned aircraft or high-end drones. Table 2 shows some of the characteristics of these sensors. Images from these sensors

allow a synoptic view of small- to medium-sized water bodies that can be monitored under different weather and water conditions with extremely high spatial and spectral resolution (SABAT-TOMALA et al., 2018). However, the high cost of scheduled field campaigns can be considered an adverse factor for their use.

Table 2 - Some of the main specifications of three hyperspectral sensors: APEX, MIVIS and HySpex.

Sensor	Spectral range	Number of bands	Spectral resolution (nm)	FOV (°)	IFOV (°)	Pixels (width)
APEX	VNIR: 380-970 SWIR: 940-2500	VNIR: 334 SWIR: 199	VNIR: 0.6-6.3 SWIR: 7-13.5	28	0.028	1024
MIVIS	I: 430-830 II: 1150-1550 III: 2.0-2.5 VI: 820-1270	I: 20 II: 50 III: 8 VI: 450	I: 20 II: 8 III: 64 VI: 10	71.1	0.114	755
HySpex	400-800 430-820 485-960 400-1000	72-88	5.5	16-40	0.016-0.039	1024

Source: Authors (2021).

UAVs have been considered a good alternative for remote sensing studies of the aquatic environment. These vehicles are often characterised as being multi-rotors or fixed-wing. The multi-rotor UAVs are normally slower than fixed-wing ones. Most multi-rotor UAVs have a battery autonomy limited to 30~minutes to a couple of hours depending on the model and payload but have the advantage of flying at lower altitudes and are able to hover while the fixed-wing can be more efficient due to their higher speed and can cover larger areas in less flight time (VAN DER MERWE; PRICE, 2015). The cameras on-board aircraft can capture images in extremely high spatial resolution, reduce revisit time, allow access to difficult areas for boats, have a lower cost than in situ campaigns and laboratory analysis and suffer less from atmospheric attenuation (KUPSSINKU et al., 2020). There are today quite a range of light weight (many under 1 kg) multispectral and hyperspectral cameras especially build for those more accessible drones (especially RGB, like Canon ELPH 110HS and Powershot S100). Although the multispectral and hyperspectral sensors on the market are relatively costly (ranging from USD 10,000 to USD 40,000), some low-cost compact sensors can also be purchased (VERONEZ et al., 2018), all depending on the ultimate goal of the research.

Conversely, because drones operate in the lower layer of the atmosphere, they are subject to significant turbulence and data collected by drones need to suffer correction and calibration that can be difficult to apply. Satellites travel at speed in excess of 6000 m.s^{-1} whereas drones are in the range of $10 - 30 \text{ m.s}^{-1}$ with the consequence that the time lag of the survey flights can imply differences in illumination and atmospheric conditions. Even if the camera is calibrated at the beginning and end of every flight, in practice it is a very complex logistic. By flying below clouds, one could think that this gives drone an advantage over satellites but in reality, the illumination changes provoked by clouds and cloud shadow can be very difficult to compensate. Problems of glare are also common depending on the sun elevation. Finally, it should be mentioned that in most cases, the ultra-high resolution achieved through drones is not necessarily an advantage as WQ phenomenon are usually characterised by a much lower operational scale.

3 OPTICALLY SIGNIFICANT WATER CONSTITUENTS

This section is dedicated to the following optically active WQ parameters: chlorophyll-a (chl-a) and phycocyanin (PC), Secchi disk depth (SDD) and turbidity.

3.1 Concentration of Chlorophyll-a (Chl-a) and Phycocyanin (PC)

Phytoplankton communities represent one of the WQ parameters that can be better detected and monitored by remote sensors. The analysis of the trophic state and WQ of a lake or reservoir is related, among

other factors, to the abundance of phytoplankton (BRESCIANI et al. 2020). The increase concentration of these species is a major cause of water contamination (PEPPA; VASILAKOS; KAVROUDAKIS, 2020). High nutrient loads (nitrogen and phosphorus) accelerate the growth and biomass production of algae (PYO et al., 2018) and can be associated with phytoplankton blooms (WILKIE et al., 2019). There is real concern about cyanotoxins blooming in water bodies as these toxins pose an effective threat to public health. Detection via remote sensing of these algal blooms in continental waters, which could contain harmful cyanobacteria, has been based on the remote estimate of chl-a and PC (OGASHAWARA, 2019).

Usually, cyanobacterial blooms appear in the morning due to the respiratory process that occurs during the absence of light, which explains the disappearance of these blooms in the afternoon and reappearance in the morning (BRESCIANI et al., 2018). Seasonal factors such as temperature rise and wind dynamics also influence the distribution, abundance and diversity of phytoplankton species (BRESCIANI et al., 2020). The time of emergence of blooms (morning) favours the use of optical remote sensing to estimate this parameter through its relationship with chlorophyll. There is a difference in the absorption and reflection of light between water with predominant concentration of phytoplankton (Case 1) and more complex water, with high levels of turbidity, CDOM and TSM (Case 2) (MALAHLELA et al., 2018). Several authors indicate the appropriateness of using algorithms like the blue/green band ratio for Case 1 (BINDING et al., 2011; WATANABE et al., 2018; ANSPER; ALIKAS, 2019; ZENG; BINDING, 2019) while the use of bands in the NIR and red regions are more applicable to the waters of Case 2, since the interference of the non-algal particle response and CDOM are reduced considerably in these regions (CHENG et al., 2013). In addition to the blue/green and NIR/red ratios to estimate the concentration of chl-a, studies often adopt a third algorithm based on spectral curvature that uses a three-band ratio: Fluorescence Line Height (FLH, which uses one band centred at 685 nm) and Maximum Chlorophyll Index (MCI, which uses a central band at 706 nm) are examples of this kind of algorithm (FLORES-ANDERSON et al., 2020).

The quantification of chl-a and PC is also possible through hyperspectral imaging. The diversity of bands of sensors like Hyperion (satellite EO-1) and CHRIS (Proba-1) allows for the application of more than 100 hyperspectral indices for providing good estimates of chl-a concentrations, achieving robust results through a four-band algorithm (Normal Chlorophyll Index – NCI, using the 550 nm, 675 nm, 690 nm and 700 nm bands) (CHENG et al., 2013). The Hyperion sensor also proved useful for complex systems with low chl-a concentrations ($<10 \text{ mg/m}^3$) (FLORES-ANDERSON et al., 2020). The AisaFENIX instrument from Specim (<https://www.specim.fi/>) has proved superior to the previous ones in WQ studies: coupled with specific atmospheric correction techniques, the sensor obtained very good performance in the quantification of chl-a from a eutrophic lake using a semi-analytical algorithm (NIR/red) (MARKELIN et al., 2017).

Although demanding higher logistic costs because of the aerial campaigns, images from MIVIS and APEX sensors were also able to validate 3D numerical hydrodynamic models of lakes, identifying potential algal blooms using semi-empirical band ratio approaches for both MIVIS (677 nm, 710 nm and 747 nm) as for APEX (670 – 673 nm and 690 – 697 nm) (PINARDI et al., 2015). Sensors on-board UAVs are capable of registering very high and ultra-high resolution images, both spatially and spectrally. The visible and NIR bands from the PIKA-L hyperspectral sensor were used to estimate chl-a and had its results compared with the products of two other sensors: the WorldView-3 multispectral and the Airborne Hyperspectral Scanner (AHS) presenting, among them, the best performance (EUGENIO; MARCELLO; MARTÍN, 2020).

Over the past twenty years, new sensors have been developed and tested to estimate chl-a and PC. VHR multispectral images, such as WorldView-2 (FERREIRA; GALO, 2013) and WorldView-3 (EUGENIO; MARCELLO; MARTÍN, 2020) were used with average results. Although the sensors have very fine spatial resolution, the spectral resolution of these sensors is often less refined. The results presented in the study involving WorldView-3 were a slightly better but still the data were not able to adequately capture the spatial variation of chl-a.

Products from the Landsat series are among the high-resolution images capable of quantifying chl-a and PC. Although the TM and ETM+ sensors have been extensively used in the last few decades (NOVO et al., 2013; OGASHAWARA et al., 2014b; HANSEN; WILLIAMS, 2018), the OLI sensor on-board Landsat-8 has been used since its launch in 2013, replacing the old sensors with better results through empirical models (WATANABE et al., 2015; MALAHLELA et al., 2018).

With the advent of the MSI instrument on-board the Sentinel-2 mission, noticeable improvement was achieved for chl-a estimates in view of the new bands in the red-edge region and its high spatio-temporal resolution (the red-edge bands have a spatial resolution of 20 m and the S-2A and -2B combined enable the acquisition of an image every five days). Studies show that empirical algorithms that associate chl-a and the green-red band ratio showed a strong correlation with data collected in situ (HA et al., 2017). For these estimates, two, three and four band algorithms were also successfully employed (HA et al., 2017; ANSPER; ALIKAS, 2019; PEPPA; VASILAKOS; KAVROUDAKIS, 2020; SÒRIA-PERPINYÀ et al., 2020). Some studies have simultaneously investigated the performance of the OLI and MSI sensors for quantifying chl-a, and showed good results for both, considering that these sensors were not designed exclusively for observing the optical constituents of water (BRESCIANI et al., 2018; WATANABE et al., 2018; PIZANI et al., 2020).

Part of another Copernicus mission, the Sentinel-3 is equipped with the OLCI sensor that has been specifically studied for the detection of chl-a and PC, either by using semi-empirical algorithms (OGASHAWARA, 2019) or by semi-analytical modelling (ZENG; BINDING, 2019). The instrument can be effective in quantifying the values of chl-a and PC due to its exclusive band centred at 620 nm, like its predecessor (MERIS), widely used and efficient for the development of bio-optical algorithms (OGASHAWARA, 2019). Together, the MSI and OLCI sensors have been integrated in recent scientific research. Although they present different characteristics, comparative analyses of their performance in lentic environments using machine learning algorithms suggest chl-a could be estimated with very similar accuracy from both sensors (PAHLEVAN et al., 2020). Models selected by optical classes of water bodies presented relevant results indicating MSI as slightly superior (SOOMETS et al., 2020). By focusing on the characteristics of the two sensors, (BRESCIANI et al., 2020) achieved a better understanding of the dynamics of phytoplankton at different time and space scales in a shallow, turbid and eutrophic lake.

Most of the above mentioned studies are listed in Table 3. Because of the large number of articles, we have restricted the list to the period 2014 – 2020. Table 4 gives a quick summary of these studies.

Table 3 - Sample of remote measurements of chl-a applied to lakes and reservoirs in the last two decades with level of accuracy obtained. Legend: L-5=Landsat-5/TM, L-8=Landsat-8/OLI, S-2=Sentinel-2/MSI, S-3=Sentinel-3/OLCI, RE=RapidEye/REIS, AHS=Airborne Hyperspectral Scanner, A/MODIS=Aqua/MODIS, T/MODIS=Terra/MODIS, E/A/ML=Empirical/Analytical/Empirical based on Machine Learning

Authors	Study Area	Platform/sensor	E/A/ML	Performance evaluation
Kupssinskü et al. (2020)	Unisinos lake; Broa's Reservoir (Brazil)	S-2 UAV/Canon ELPH 110HS	ML	Mean values for the evaluated metrics: Unisinos: $r^2=0.90$, MSE=0.005 $\mu\text{g/L}$; Broa's: $r^2=0.82$, MSE=0.005 $\mu\text{g/L}$
Pahlevan et al. (2020)	Optically different waters (10 countries)	S-2 S-3	ML	Mixture Density Network S-2: RMSE=30.31 μm^3 , MAPE=24% S-3: RMSE=26.98 μm^3 , MAPE=23
Uudeberg et al. (2020)	51 lakes (Estonia and Finland)	S-2 S-3	E	S-2: $r^2=0.85$; S-3: $r^2=0.86$
Flores-Anderson et al. (2020)	Lake Atitlan (Guatemala)	EO-1	E	$r^2=0.70$, RMSE=2.005 mg/m ³
Soomets et al. (2020)	4 Baltic lakes (Estonia and Latvia)	S-2 S-3	E	S-2: $r^2=0.84$, RMSE=10.49 mg/m ³ ; S-3: $r^2=0.83$, RMSE=9.79 mg/m ³
Li et al. (2020)	Donghu lake (China)	L-8	ML	MSE=17.81
Eugenio et al. (2020)	Maspalomas lagoon (Spain)	WV-3 AHS UAV/Pika-L	A	WV-3: RMSE=6.75 $\mu\text{g/L}$; AHS: RMSE=6.65 $\mu\text{g/L}$; UAV: RMSE=3.49 $\mu\text{g/L}$
Van Nguyen et al. (2020)	Lake Kasumigaura (Japan)	MERIS	E	$r=0.89$, RMSE=6.37 mg/m ³
Sòria-Perpinyà et al. (2020)	Albufera of València lagoon (Spain)	S-2	E	Calibration: $r^2=0.84$; Validation: $r^2=0.77$, RMSE=141.0 $\mu\text{g/L}$
Peppa, Vasilakos and Kavroudakis (2020)	Lake Pamvotis (Greece)	S-2	E	MCI and MPH (Maximum Peak-Height): Pearson's r values up to 0.95
Bresciani et al. (2020)	Lake Trasimeno (Italy)	S-2 S-3	A	Combination of S-3 and S-2 data: Cross-validated $r^2=0.97$

(To be continued)

(Continuation 221)

Authors	Study Area	Platform/ sensor	E/A/ ML	Performance evaluation
Neil et al. (2019)	185 global inland and coastal aquatic systems	MERIS	E/A/ ML	Variability unknown: (E) $r=0.88$, RMSE=0.256 mg/m ³ ; Predominantly clear water/oligotrophic: (E) $r=0.82$, RMSE=0.306 mg/m ³ ; Blue to green water/mesotrophic: (E) $r=0.88$, RMSE=0.256 mg/m ³ ; Green or brown water/hypereutrophic: (A) $r=0.87$, RMSE=0.267 mg/m ³
Zeng and Binding (2019)	Lake Winnipeg & Erie (Canada)	S-3	E	$r^2=0.97$, RMSE=6.0 mg/m ³
Ogashawara (2019)	Lake Erie (USA)	S-3	E	PC > 50 µg/L: $r^2=0.22$, RMSE=207.167 µg/L; Chl-a > 50 µg/L: $r^2=0.38$, RMSE=107.585 µg/L
Wilkie et al. (2019)	Lake Balaton (Hungary)	MERIS	A	RMSE=0.445 mg/m ³ , MAE=0.355 mg/m ³
Elhag et al. (2019)	Baysh Dam (Saudi Arabia)	S-2	E	$r^2=0.96$, RMSE=0.039628 mg/m ³
Ansper and Alikas (2019)	Estonian inland lakes (Estonia)	S-2	E	Results varied according to the water type: $r^2=0.20$ to $r^2=0.97$
Hansen and Williams (2018)	Deer Creek Reservoir; Jordanelle Reservoir; Utah Lake (USA)	L-5 L-7	E	Reservoirs whole season: $r^2=0.12$, RMSE=24.7 µg/L; Early season: $r^2=0.54$, RMSE=1.5 µg/L; Mid season: $r^2=0.32$, RMSE=5.4 µg/L; Late season: $r^2=0.73$, RMSE=23.7 µg/L Utah Lake whole season: $r^2=0.50$, RMSE=55.2 µg/L; Early season: $r^2=0.99$, RMSE=1.2 µg/L; Late season: $r^2=0.88$, RMSE=14.4 µg/L
Bresciani et al. (2018)	Lake Maggiore; Lake Como; Lake Iseo; Lake Idro; Lake Garda (Italy)	L-8 S-2	A	Mean values: $r^2=0.82$, RMSE=0.43 mg/m ⁻³
Blix et al. (2018)	Lake Balaton (Hungary)	S-3	ML	$r^2=0.83$, NRMSE=0.1042 mg/m ³
Bonansea, Rodrigues and Pinotti (2018)	Río Tercero Reservoir (Argentina)	L-5 L-7 L-8	E	$r^2=0.89$, NRMSE=18.8 µg/L
Odermatt et al. (2018)	24 lakes and multiple reservoirs (4 continents)	MERIS	E/ ML	Global results: (E) $r=0.64$, MAE=7.726 mg/m ⁻³ ; (ML) $r=0.59$, MAE=2.447 mg/m ⁻³
Pyo et al. (2018)	Baekje Reservoir (South Korea)	AHS	A	PC: $r^2=0.77$, RMSE=14.90 mg/m ³ ; Chl-a: $r^2=0.53$, RMSE=10.88 mg/m ³
Markogianni et al. (2018)	Trichonis Lake (Greece)	L-8	E	Log chl-a: $r^2=0.33$, Std. Err.=0.12 µg/L; chl-a: $r=0.44$, $r^2=0.19$, Std. Err.=0.13 µg/L
Binding et al. (2018)	Lake Winnipeg (Canada)	MERIS	E	$r^2=0.83$, p-value < 0.01
Torbick et al. (2018)	New England lakes (USA)	L-7 L-8	A	$r^2=0.86$, RMSE=11.92 µg/L
Watanabe et al. (2018)	Barra Bonita Reservoir (Brazil)	L-8 S-2	E	L-8: $r^2=0.22$, RMSE=84.95 mg/m ³ ; S-2: $r^2=0.76$ -0.85, RMSE=69.24-127.41 mg/m ³

(To be continued)

(Conclusion)

Authors	Study Area	Platform/ sensor	E/A/ ML	Performance evaluation
Sabat-Tomala et al. (2018)	Zegrze Reservoir (Poland)	Cessna 402B Aeroplane/ HySpex scanner	E	$\rho=0.43$
Malahlela et al. (2018)	Vaal Dam (South Africa)	L-8	E	$r^2=0.61$
Coelho et al. (2017)	3 reservoirs: Marengo, Pau Branco, São Nicolau (Brazil)	L-8 RE	E	L-8 all reservoirs: $r^2=0.13-0.28$, NSE=-3.89 to -0.45; RE all reservoirs: $r^2=0.20-0.40$, NSE=-0.40 to 0.71 $\mu\text{g/L}$
Markelin et al. (2017)	Loch Leven Lake (UK)	AHS (AisaFENIX)	A	RMS=5.87 mg/m^{-3}
Philipson et al. (2016)	Lake Vänern (Sweden)	MERIS	E	$r=0.85$, MAE=0.9 $\mu\text{g/L}$
Barrett and Frazier (2016)	Lake Eufaula (USA)	L-5 L-7	E	Chl-a: $r=-0.154$; lnChl-a: $r=-0.155$
Toming et al. (2016)	11 lakes (Estonia)	S-2	E	Chl-a TOA: $r^2=0.83$; Chl-a BOA: $r^2=0.80$
Torbick and Corbiere (2015)	Lake Champlain (USA)	L-8 Proba-1 RE	E	Chl-a: L-8: $r^2=0.77$, RMSE=0.41 $\mu\text{g/L}$; Proba-1: $r^2=0.88$, RMSE=0.54 $\mu\text{g/L}$; RE: $r^2=0.81$, RMSE=1.46 $\mu\text{g/L}$; PC: L-8: $r^2=0.83$, RMSE=1.33 $\mu\text{g/L}$; Proba-1: $r^2=0.88$, RMSE=1.02 $\mu\text{g/L}$; RE: $r^2=0.77$, RMSE=1.52 $\mu\text{g/L}$
Watanabe et al. (2015)	Barra Bonita Reservoir (Brazil)	L-8	E	Values varied between: $r^2=0.39$ and $r^2=0.75$
Politi, Cutler and Rowan (2015)	European lakes: Vänern, Vättern, Geneva, Balaton	Aqua/MODIS Terra/MODIS	E	Aqua/Terra: $r^2=0.014$; Terra: r^2 ranging from $r=0.76$ to 0.79 in oligotrophic lakes
Palmer et al. (2015a)	Lake Balaton (Hungary)	MERIS	E	FLH: $r^2=0.87$, RMSE=4.19 mg/m^3 ; MCI: $r^2=0.69$, RMSE=6.62 mg/m^3
Palmer et al. (2015b)	Lake Balaton (Hungary)	MERIS	E	Values varied between: $r^2=0.58$ and $r^2=0.84$
Xiang et al. (2015)	Chaohu Lake (China)	Terra/MODIS	E	Values varied between: $r^2=0.57$ and $r^2=0.89$, MSE=5.3452 and MSE=10.4689
Ogashawara and Moreno-Madriná (2014)	Lake Thonotosassa (USA)	MODIS	E	r^2 and RMSE by quarter: Jan-Mar: 0.53, 45.2 $\mu\text{g/L}$; Apr-Jun: 0.56, 112.08 $\mu\text{g/L}$; Jul-Sep: 0.67, 62.02 $\mu\text{g/L}$; Oct-Dec: 0.06, 27.16 $\mu\text{g/L}$
Mishra and Mishra (2014)	15 aquaculture ponds (USA)	MERIS	E	Full-range PC model: $r^2=0.99$, MRE=30.71% Model for PC < 300 $\mu\text{g/L}^{-1}$: $r^2=0.65$, MRE=38.18%
Ogashawara et al. (2014a)	Itumbiara Hydroelectric Reservoir (Brazil)	Terra/MODIS	E	OC2: $r^2=0.10$, RMSE=37.03%; OC3: $r^2=0.19$, RMSE=44.02%
Torbick et al. (2014)	4453 lakes (USA)	L-5	E	Regression coefficient=0.045, Std. Error=0.024, p-value=0.0678
Huo et al. (2014)	Water bodies in Xi'na City (China)	L-7	ML	$r^2=0.97$, MAD=9.533 mg/L
Coelho et al. (2011)	Lago do Amor Reservoir (Brazil)	CBERS/CCD	E	Best result: Normalized Ratio Aquatic Vegetation Index (NRAVI) $r^2=0.91$

Source: Authors (2021).

Table 4 - Summary of Chlorophyll-a/Phycocyanin studies.

223

Most successful sensors		Best bands & indices	Limitations	Other comments
Low res.	High res.			
S-3, MERIS, MODIS	S-2, L-8, L-5	Blue/green, NIR/red (case 2 water), RE/red, narrow 620 nm (red), 3-and 4-band algo.	Complex water (case 2) can be very challenging. Higher concentrations might be necessary for using NIR & RE bands	High spectral resolution is more critical for chl-a. Hyperspectral can be an advantage. Normalised versions of the indices might be better.

Source: Authors (2021).

3.2 Secchi Disk Depth (SDD) and Transparency

The Secchi disk is a circular instrument with a diameter measuring between 20 and 30 cm, usually black and white, attached to a measuring tape and dedicated to the vertical measurement of the water transparency through immersion. The reading is made by an observer who determines the depth at which the disk seems to disappear below the water surface (LIU et al., 2019). SDD is widely used due to easy interpretation and application (TORBICK et al., 2014). This measurement is based on a theory of under-water visibility (VUNDO et al., 2019). Light attenuation implies in greater or lesser water clarity which depends directly on the concentration of suspended substances (SABAT-TOMALA et al., 2018), such as phytoplankton, organic and inorganic matter, and the proportion of clear water (LIU et al., 2019). The best time to estimate this parameter is around noon (AVDAN et al., 2019) but a correction factor can be applied to correct for sun elevation (VERSCHUUR, 1997).

The water transparency assessment represents an important factor in the monitoring and management of water resources (BONANSEA et al., 2015) for many reasons. Activities within the watershed can affect water transparency due to the carrying of sediments loads and nutrients (RODRIGUES et al., 2017). The algae proliferation process can modify the water clarity and reaches its peak in late summer, which is the period most propitious for lakes and reservoirs to show smaller SDD values (KNIGHT; VOTH, 2012).

Monitoring water transparency by remote sensing can be effective and offer advantages such as the possibility of creating models based on satellite images with only a few sampling points surveyed in the field (KNIGHT; VOTH, 2012). The main remote sensing algorithms applied to estimate SDD in the last twenty years were based on empirical or semi-analytical relationships (LIU et al., 2019).

Turbidity is a parameter that contains optical properties similar to SDD properties and, in some cases, may allow the same spectral bands combination to be used to estimate SDD (AVDAN et al., 2019). Red and blue regions of the electromagnetic spectrum are widely used to assess water clarity. The reflectance in the red band is directly proportional to the increase in turbidity, while the blue band responds inversely in proportion to the optical properties of substances that promote greater water turbidity (KNIGHT; VOTH, 2012). Combinations of visible bands (red, green and blue) have often been used in the construction of algorithms for SDD estimates in optically complex continental water (MANCINO et al., 2009; STEFOULI; CHAROU, 2012; RODRIGUES et al., 2017; VUNDO et al., 2019).

Remote sensing models with good levels of significance for SDD estimation have been applied to MODIS (LIU et al., 2019; VUNDO et al., 2019) and MERIS products (KNIGHT; VOTH, 2012; XIANG et al., 2015; POLITI; CUTLER; ROWAN, 2015; ZHANG et al., 2016) in large water bodies (>160 ha), a restriction dictated by the low spatial resolution of these sensors (KNIGHT; VOTH, 2012; LIU et al., 2019).

Images from Landsat sensors (TM, ETM+ and OLI) were used to measure SDD in multiple scientific research, providing satisfactory predictive relationships for specific studies ($r^2 > 0.66$) in lakes and reservoirs (MANCINO et al., 2009; HUO et al., 2014; TORBICK et al., 2014; BONANSEA et al., 2015; XU et al., 2018). Comparing the results of the algorithms applied to the images of the OLI and MSI sensors using an analytical approach, Rodrigues et al. (2017) found that the response from OLI outperformed that of MSI products attesting its applicability in oligo-mesotrophic waters.

Recent studies have used an approach guided by optical types of water and using data from the MSI and OLCI sensors in order to compare their results and showed a high correlation between MSI sensor data

and SDD values (SOOMETS et al., 2020; UUDEBERG et al., 2020). Although the MSI sensor has been designed mostly for terrestrial monitoring, current research shows that the development of specific algorithms and methods produced good results using data from this sensor (SOOMETS et al., 2020).

Studies that measure SDD from optical sensors have a relatively high level of success (Table 5) in part because SDD is a direct consequence of all optical characteristics of water and the elements it contains. The summary is presented in Table 6.

Table 5 - Sample of remote measurements of SDD applied to lakes and reservoirs in the last two decades and level of accuracy obtained. Legend: L-5=Landsat-5/TM, L-8=Landsat-8/OLI, S-2=Sentinel-2/MSI, S-3=Sentinel-3/OLCI, RE=RapidEye/REIS, AHS=Airborne Hyperspectral Scanner, A/MODIS=Aqua/MODIS, T/MODIS=Terra/MODIS, E/A/ML=Empirical/Analytical/Empirical based on Machine Learning

Authors	Study Area	Platform/ sensor	E/A/ ML	Performance evaluation
Uudeberg et al. (2020)	51 Baltic lakes (Estonia and Finland)	S-2 S-3	E	S-2: $r^2=0.83$; S-3: $r^2=0.82$
Soomets et al. (2020)	4 Baltic lakes (Estonia and Latvia)	S-2 S-3	E	S-2: $r^2=0.97$, RMSE=0.36 m; S-3: $r^2=0.69$, RMSE=1.10 m
Avdan et al. (2019)	Borabey Dam (Turkey)	RE	E	$r=-0.86$
Liu et al. (2019)	Lake Taihu (China)	MERIS	A	$r^2=0.73$, MAPD=37%
Vundo et al. (2019)	Lake Malawi (Malawi)	MERIS	A	Lee15 algorithm: $r=0.66$, RMSE=1.17 m; Doron11 algorithm: $r=0.65$, RMSE=3.68 m
Xu et al. (2018)	Lake Liangzi (China)	L-7 L-8	E	Estimated vs In situ measured (2016): $r^2=0.66$, RMSE=0.118 m Long-term trend (2007-2016): $r^2=0.35$, p-value < 0.001
Sabat-Tomala et al. (2018)	Zegrze Reservoir (Poland)	AHS	E	$p=0.52$
Rodrigues et al. (2017)	Nova Avanhandava Reservoir (Brazil)	L-8 S-2	A	L-8 (QAAv5 algorithm): Values between MAPE=12,86% and MAPE=31,17% S-2 (QAAM14 algorithm): Values between MAPE=14,33% and MAPE=39,13%
Politi, Cutler and Rowan (2015)	Vänern Lake; Vättern Lake; Geneva Lake (European continent)	A-T/MODIS	E	Best results Geneva Lake A-T: $r=0.245$ Aqua: $r=-0.317$ Terra: $r=0.789$ Best results Vänern and Vättern Lakes A-T: $r=-0.542$ Aqua: $r=-0.871$ Terra: $r=0.924$ Best results all lakes A-T: $r=-0.230$ Aqua: $r=-0.667$ Terra: $r=0.308$
Xiang et al. (2015)	Chaochu Lake (China)	T/MODIS	E	Values between $r^2=0.57$ and $r^2=0.89$, MSE=5.3452 and MSE=10.4689
Bonansea et al. (2015)	Rio Tercero Reservoir; Los Molinos Reservoir (Argentina)	L-5 L-7	E	$r^2=0.81$, RMSE=0.64 m
Giardino et al. (2014)	Lake Garda (Italy)	L-8 RE	A	L-8 and RE: $r=0.72$
Torbick et al. (2014)	4453 lakes (USA)	L-5	E	Regression coefficient=-0.921, Std. Error=0.231, p-value=0.0001
Huo et al. (2014)	Water bodies in Xi'an City (China)	L-7	ML	$r^2=0.98$, MAD=0.736 m

Source: Authors (2021).

Table 6 - Summary of SDD studies.

225

Most successful sensors		Best bands & indices	Limitations	Other comments
Low res.	High res.			
S-3, MERIS, MODIS	S-2, L-8, L-7, L-5	Red & blue, visible bands	Subjective, measurements may differ by operator. Should be corrected to compensate sun elevation & atmospheric condition	Easy to acquire field data, easy to interpret.

Source: Authors (2021).

3.3 Turbidity

Turbidity is an optically active property of water that indicates the presence of particles in the water column that can provoke the scattering or absorption of light (POTES; COSTA; SALGADO, 2012; AVDAN et al., 2019). This is an important WQ indicator (QUANG et al., 2017) adopted by most monitoring programs (ODERMATT et al., 2018). Turbidity can be caused by the presence of matter of phytoplanktonic origin and an increase in turbidity can be associated to the number of plant pigments in the water column (SABAT-TOMALA et al., 2018). Materials of mineral origin from soil erosion also contribute to water turbidity (MENKEN; BREZONIK; BAUER, 2006). Notwithstanding the specific characteristics of each indicator, TSM and turbidity can be considered directly correlated parameters (ODERMATT et al., 2008).

Turbidity is more frequently observed in stable lentic environments with low water flow (SABAT-TOMALA et al., 2018). High levels of turbidity imply lesser water transparency and can cause imbalances and damage to biological organisms (QUANG et al., 2017). The effects of turbidity can be represented by the change and evolution of the temperature measured on the water surface (POTES; COSTA; SALGADO, 2012). Turbidity can be quantified by nephelometry or estimated by SDD through observations from the surface (QUANG et al., 2017). However, Secchi's observations may present greater uncertainties when compared to other instrumental measurement methods (SON; WANG, 2019).

Although considered an effective method, the use of remote sensing for estimating WQ parameters in complex continental aquatic environments, with high levels of turbidity is still a challenge (ROBERT et al., 2017). The use of the red spectral range in single band algorithms can produce extremely consistent and robust models for turbidity in highly turbid water using high-resolution sensors, such as Landsat-OLI (QUANG et al., 2017). However, ratio models of two or more spectral bands are more commonly used. The two-band models using the 412 nm and 560 nm wavelengths showed good estimates with low spatial resolution images from MERIS (POTES; COSTA; SALGADO, 2012), as well as using high-resolution images from the MSI (ELHAG et al., 2019) and REIS (AVDAN et al., 2019) sensors combining the green and red bands. Good results were also obtained with hyperspectral data from HySpex scanner adopting the red-edge ranges at 705 nm and 714 nm (SABAT-TOMALA et al., 2018). In general, the literature indicates that a good accuracy in turbidity prediction is possible using visible bands (SILVA et al., 2020) and the combination of visible and infrared bands (ALPARSLAN; COSKUN; ALGANCI, 2010). Good results are described with both empirical and analytical models but the choice of spectral regions for the development of turbidity estimation algorithms may also be dependent on the season, especially in eutrophic environments (BARRETT; FRAZIER, 2016). Table 7 shows a sample of studies from the last decade while Table 8 presents the turbidity summary .

Table 7 - Sample of remote measurements of turbidity applied to lakes and reservoirs in the last two decades and level of accuracy obtained. Legend: L-5=Landsat-5/TM, L-8=Landsat-8/OLI, S-2=Sentinel-2/MSI, S-3=Sentinel-3/OLCI, RE=RapidEye/REIS, AHS=Airborne Hyperspectral Scanner, A/MODIS=Aqua/MODIS, T/MODIS=Terra/MODIS, E/A/ML=Empirical/Analytical/Empirical based on Machine Learning

Authors	Study Area	Platform/ sensor	E/A/ ML	Performance evaluation
Facco et al. (2021)	Itaipu Reservoir (Brazil)	L-8	E	Best results: $r^2=0.94$ (red band) $r^2=0.91$ (NDTI)

(To be continued)

Authors	Study Area	Platform/ sensor	E/A/ ML	Performance evaluation
Silva et al. (2020)	Alton Water Reservoir (UK)	L-8 S-2	ML	Wavelet Artificial Neural Networks: NMSE=0.01404, MSE=0.00885
Avdan et al. (2019)	Borabey Dam (Turkey)	RE	E	r=0.93
Son and Wang (2019)	Great Lakes (USA/Canada)	SNPP/VIIRS	A	r=0.93
Elhag et al. (2019)	Baysh Dam (Saudi Arabia)	S-2	E	r ² =0.94, RMSE=0.077774 NTU
Abdelmalik (2018)	Qaroun Lake (Egypt)	ASTER	E	r ² =0.99, RMSE=0.891 NTU
Odermatt et al. (2018)	24 lakes and multiple reservoirs (4 continents)	MERIS	E	r=0.74, MAE=0.88 NTU
Sabat-Tomala et al. (2018)	Zegrze Reservoir (Poland)	AHS	E	p=0.54
Quang et al. (2017)	Thuy Trieu Lagoon; Cam Ranh Bay (Vietnam)	L-8	E	r ² =0.84, RMSE=0.28 NTU
Barrett and Frazier (2016)	Lake Eufaula (USA)	L-5 L-7	E	Turbidity: r=N/A; lnTurbidity: r=0.43
Potes, Costa and Salgado (2012)	Alqueva Reservoir (Portugal)	MERIS	E	r=0.96, RMSE=3.62 NTU
Alparslan, Coskun and Alganci (2010)	Darlik Dam (Turkey)	L-5	E	r=0.92
Alparslan, Coskun and Alganci (2009)	Küçükçekmece Lake (Turkey)	L-5 IRS-1C/D LISS SPOT	E	r ² =0.82

Source: Authors (2021).

Table 8 - Summary of turbidity studies.

Most successful sensors		Best bands & indices	Limitations	Other comments
Low res.	High res.			
MERIS	ASTER, S-2, L-8, L-7, L-5	Red (only), green/blue, visible bands, RE, NIR	The greater the turbidity, the shallower the estimate. Turbidity affects measurements of other parameters like chl-a and CDOM	Highly turbid water can produce good models with only the red band.

Source: Authors (2021).

4 SCIENTIFIC AND TECHNOLOGICAL ADVANCEMENTS IN THE PAST TWO DECADES

Some of the biggest advances in studies involving aquatic remote sensing have been cloud computing and storage platforms that facilitate large-scale remote sensing analysis. Improved computing power has allowed for faster and more complex data analysis. Technologies such as Google Earth Engine (GEE), Amazon Web Services (AWS) and Siemens Xcelerator are examples of cloud-based computing platforms that can allow processing of big data for which the computational cost is usually high, a frequent problem in processing large number of image and other remote sensing data (SAGAN et al., 2020).

For remote sensing data, GEE is arguably the cloud computing platform that best serves intense users (MACIEL et al., 2021). GEE is a remote sensing information portal launched in 2010 that consists in a data catalogue providing time series of satellite images from various missions as well as vector data allowing to apply processing algorithms developed by the user or the remote sensing community (GORELICK et al., 2017; KUMAR; MUTANGA, 2018). Especially in the last five years, a number of studies have been carried out using GEE to monitor WQ parameters such as TSM (MARKERT et al., 2018; CAO et al., 2019; CABALLERO; NAVARRO, 2021), SDD (PAGE; OLMANSON; MISHRA, 2019; LIU et al., 2020) and chl-a (LIN et al., 2018; WANG et al., 2020; CABALLERO; NAVARRO, 2021; LOBO et al., 2021).

Machine Learning (ML) is an approach based on AI (Artificial Intelligence) increasingly applied to develop self-learning algorithms that can handle large number of variables from which a “characteristic” behaviour can be determined (RUSSELL; NORVIG, 1995; SAGAN et al., 2020). By definition ML needs example data or past experience and is therefore empirical and can handle non-parametric distributions of data. In addition, ML can be dynamic and adapt itself over time as new data is brought in (KIM et al., 2014; LARY et al., 2016; ALPAYDIN, 2020). It can be used to solve problems of classification, pattern recognition, outlier detection, and regression among other applications and can do both supervised and unsupervised learning (ALPAYDIN, 2020). Because ML algorithms are generally the result of “mining” large data base and using large number of variables, they are considered more robust than pure regression approaches (HAFEEZ et al., 2019). In a study involving eight lakes in Midwestern United States, Sagan et al. (2020) found that ML approaches yielded the best overall results for a number of WQ parameters including TSM, turbidity and chl-a. ML generally needs large amount of data to be efficient, and this can be a limitation in WQ applications which typically use limited amount of data unless carried out over many lakes or rivers at once.

There are a number of ML algorithms that can be used to assess WQ through remote sensing techniques, some of which are: Support Vector Regression (SVR), Gaussian Processes Regression (GPR), self-organising map (SOM), artificial neural networks, Random Forest, genetic algorithms, among others (LARY et al., 2016; PU et al., 2019; ZHANG et al., 2020). Even though ML algorithms have shown to perform well for studies involving WQ models, they can suffer from problems such as excessive dimensionality and overfitting (KUPSSINSKU et al., 2020). In addition, the type of distribution of the entry data and their associated uncertainties can strongly affect the accuracy of the results (PAHLEVAN et al., 2020).

In WQ studies, one limitation often comes from the relative scarcity of in situ data worldwide (HEAL et al., 2021). The difficulty of acquiring in situ data often results in relatively small sample sizes being used for calibrating and validating WQ models (TOPP et al., 2020). Recent years have seen the emergence of large and even global data base of WQ in situ data made accessible to the scientific community that have contributed toward the development of more generic WQ models. These data base can be invaluable for the validation and calibration of models developed for the quality of continental waters. The GEMStat Water Program is one such global data portal of the United Nations Environment Program (UNEP) hosted by the GEMS/Water Data Center (GWDC) of the International Centre for Water Resources and Global Change (ICWRGC), Koblenz, Germany (UNEP, 2021; HEAL et al., 2021). Through the portal <https://gemstat.org/>, it is possible to access WQ data from more than 75 countries on rivers, lakes and wetlands (TOPP et al., 2020). In the European Union, the Copernicus Global Land Service (CGLS), which is part of the Copernicus land monitoring program is a platform hosted by the European Commission Joint Research Centre (JRC) that provides sensor and in situ data on turbidity, trophic state index and reflectance of the aquatic surface of lakes with a spatial resolution of 100 m (Europe and Africa, from the MSI/Sentinel-2 sensor), 300 m and 1 km (global data, from the MERIS/ENVISAT and OLCI/Sentinel-3 sensors). In addition to WQ data, the portal provides information on lake surface temperature and water level (CGLS, 2021). In partnership with the United States Geological Survey (USGS), the Environmental Protection Agency (EPA), the National Water Quality Monitoring Council (NWQMC) and more than 400 state, federal, local and tribal agencies, the Water Quality Portal (WQP) is a collaborative service that provides information from more than 297 million WQ files from the 50 states of the United States (READ et al., 2017). The rapid growth of these portals is likely to be a major contribution to WQ models in the near future.

5 LIMITATIONS

Remote sensing offers a number of advantages to estimate WQ in lakes and reservoirs. The spatio-temporal coverage, the analysis of bodies of water inaccessible to man, the rapid data acquisition and the recovery of historical data through time series are some of these advantages (ANSWER; ALIKAS, 2019; ZHAO et al., 2020; TOPP et al., 2020). However, it is worthwhile mentioning the existence of restrictions that are inherent to its application. The dependence on good climatic conditions, as well as the spatial and temporal variation of air masses and solar illumination can be considered limiting factors (ANSWER; ALIKAS, 2019). The optical image products may present atmospheric interference capable of negatively affecting or even

preclude the results (VERONEZ et al., 2018).

228

The spatial resolution of images can also be a limiting factor for small lakes, ponds and small reservoirs. Images of low or moderate resolution like MODIS (250 – 1000 m), Sentinel-3/OLCI (300 m) or Proba-V (300 – 600 m) can have very limited application for water bodies smaller than 2500 km² due to the large number of pixels with a mixture of land and water (MERTES et al., 2004; CUI et al., 2013; VERONEZ et al., 2018). Likewise, sensors with low spectral resolution might not be appropriate for monitoring WQ parameters which can be related to very specific portions of the electromagnetic spectrum. It is the case of PC for example, which shows a narrow absorption peak around 620 nm (OGASHAWARA, 2019) or the chl-a which is better quantified with sensors having red-edge band ($\approx 690 - 740$ nm). In addition, sensors of very high spatial resolution are mostly found in commercial satellites and can present a prohibitive cost for research in large lakes and reservoirs. The same applies to most hyperspectral sensors which are only available for aerial operations (with the possible exception of EO-1/Hyperion decommissioned March 2017).

The temporal resolution or revisit capacity is another factor that can prevent effective monitoring if the frequency desired is greater than the satellite revisit capacity or if the local atmospheric conditions do not allow clear sky often enough (VERONEZ et al., 2018). It might also be necessary to perform in situ measurement synchronised with the sensor overpass which can impose further restrictions (WILKIE et al., 2019).

Continental water bodies are often very complex and vary enormously from one region to the other. As such, it is generally inadvisable to compare concentrations measured through remote sensing from one water body to another since some algorithms demand to be calibrated locally and might not be replicable in other areas (ODERMATT et al., 2018) especially if these areas are distant and subjected to different environmental conditions. Concentrations of water constituents can be influenced by submersed vegetation or by other sources originating from the bottom and these can directly affect the radiance/reflectance at the surface and produce false estimates (CUI et al., 2013). Because remote sensing is limited to measurements in superficial waters, only three-dimensional models can help to explain the behaviour of these particles in suspension throughout the water column (MARKERT et al., 2018).

Some remote sensing results also strongly depend on local analysis. For example, it can be used to estimate the concentration and distribution of cyanobacteria but cannot identify their type or the number of different toxins they produce which is really what matters in terms of health hazard (VAN DER MERWE; PRICE, 2015). Similarly, if remote sensing can give good estimates of suspended solids, it does not directly inform about the transport dynamics (MARKERT et al., 2018).

At last, many important parameters cannot be measured directly simply because they do not affect the optical properties of water in the wavelengths (position and width) used by the available sensors. Although some success has been obtained in estimating these parameters because of their relationship with other OA parameters, these approaches are essentially empirical and a better understanding of these relations will require complex models involving many parameters, some of which might not be estimated through remote sensing.

6 CONCLUSIONS

Our review revealed that the past two decades have produced an exponentially growing mass of articles on the subject of remote sensing applied to the quantitative estimation of WQ parameters. A total of 127 articles were collected. We have concentrated our review on lentic environments (mostly lakes and reservoirs) for which there is a very wide range of platforms and sensors that covers from moderate spatial resolutions useful for large lakes and reservoirs to the very high- (< 1 m) and even ultra-high-resolutions (< 0.1 m) that can be achieved from commercial satellites.

Even though the empirical methods of correlation and regression still dominate broadly the range of approaches used, other more complex methods like neural network and deep learning are gaining terrain in terms of popularity. Analytical and semi-analytical approaches are also being used but in much lesser proportion. They are mainly applied to chl-a and Secchi disk depth and appear to achieve results comparable to empirical approaches. The important advantage of analytical approaches resides in their theoretical independence from in situ data once the model is calibrated and are more exportable to different environments, both timely and geographically. They do however, involve more control over the environmental variables

affecting the optical characteristics of water.

229

We also found that there is a general consensus in many articles in terms of the spectral bands used to model the parameters considered in this paper. In all cases wavelengths covered by the visible bands have a predominant role because of their ability to penetrate water and be sufficiently reflected or absorbed by exotic elements present within the first centimetres to few metres below the surface. The red band bears a significant importance, most notably for all optically active components (chl-a, SDD and turbidity). The blue band is more present for SDD and turbidity, but because the blue light is scattered about five times more than red (see Jensen (2005, p. 187)), atmospheric attenuation can be an issue with the blue band (TOMING et al., 2016). The near infrared is mostly used in chl-a models but usually in combination with one or more band in the visible spectrum.

One notable “newcomer” in the spectral band realm is the “red-edge” band ($\approx 690 - 740$ nm) that first appeared in a civil satellite with the RapidEye constellation of five satellites (RapidEye Basic Product) launched in 2008. The red-edge band has proven to be good for chl-a but also for turbidity. Instruments on-board the Sentinel-2 and -3 satellites as well as some commercial VHR satellites (e.g., WorldView) all have one or more red-edge band. Another more subtle improvement that might have contributed in producing good results for many of the recent studies resides in the increase in spectral resolution of recent instruments on-board satellites. The Sentinel-2 (MSI instrument) and -3 (OLCI instrument) as well as Landsat-8 (OLI), RapidEye (REIS) and MODIS all have relatively narrower spectral bands than earlier satellite instruments. With the launch of many new satellites in the foreseeable future (Sentinel-2C/MSI, Sentinel-3C/OLCI, ResourceSat-3/ALISS III, Landsat-9/OLI-2, JPSS-2/VIIRS, HyspIRI, EnMAP e PACE/OCI), these improvements are likely to continue.

Throughout this review, it stood out that the results can vary broadly in part because of the variety of instruments and approaches used. It also became clear through some articles that environmental factors such as season, atmospheric conditions, type and complexity of water can have an important effect on the quality of the results. It gives an indication on the kind of general results that can be expected. Chl-a for instance can yield results with much greater variation than SDD. It appears to be less reliable when the levels are very low. Our opinion after consulting over 180 articles, 143 of which we quoted, is that these environmental factors might be more determinant on the accuracy of the results than the actual approach used. The instruments used (satellite/sensor) is probably the next factor in importance with an emphasis on the wavelength and bandwidth of the spectral bands available. Conversely, because water is a poor reflector, the narrower the spectral band, the less energy is reflected back towards the sensor. This is a paradoxical limitation for which a solution strongly depends on technological advancements.

Acknowledgements

This work was produced within the frame of a wider project entitled “Intelligent Water Quality Monitoring through the Development of Photo-optical Algorithm” and financed by the Companhia Energética de Minas Gerais (CEMIG, project GT-0607). The authors are most grateful to the GT-0607 Team who made this article possible.

Authors' Contribution

The Fernanda Pizani (first author) was responsible for Conceptualization, Research and Methodology, Visualization and Writing – initial draft and editing. The Philippe Maillard (second author) was responsible for Conceptualization, Supervision and Writing – review and editing. The Camila Amorim (third author) was responsible for Conceptualization and Proofreading.

Conflict of interest

The authors declared no potential conflicts of interest with respect to the research, authorship, and/or publication of this article.

References

- ABDELMALIK, K. Role of statistical remote sensing for inland water quality parameters prediction. **The Egyptian Journal of Remote Sensing and Space Science**, v.21, n.2, p.193-200. September 2018, DOI. 10.1016/j.ejrs.2016.12.002.
- ALCÂNTARA, E.H.; STECH, J.L.; LORENZZETTI, J.A.; NOVO, E.M.L.M. Time series analysis of water surface temperature and heat flux components in the Itumbiara Reservoir (GO), Brazil. **Acta Limnologica Brasiliensis**, v.23, n.3, p.245-259, September 2011, DOI. 10.1590/S2179-975X2012005000002.
- ALPARSLAN, E.; COSKUN, H.G.; ALGANCI, U. Water quality determination of Küçükçekmece Lake, Turkey by using multispectral satellite data. **The Scientific World Journal**, v.9, p.1215-1229, November 2009, DOI. 10.1100/tsw.2009.135.
- ALPARSLAN, E.; COSKUN, H.G.; ALGANCI, U. An investigation on water quality of Darlik Dam drinking water using satellite images. **The Scientific World Journal**, v.10, 1293-1306, May 2010, DOI. 10.1100/tsw.2010.125.
- ALPAYDIN, E. **Introduction to machine learning**. 4ed. Cambridge, Massachusetts: The MIT Press, 2020.
- ANSPER, A.; ALIKAS, K. Retrieval of chlorophyll a from Sentinel-2 MSI data for the european union water framework directive reporting purposes. **Remote Sensing**, v.11, n.1, January 2019. DOI. 10.3390/rs11010064.
- AVDAN, Z.Y.; KAPLAN, G.; GONCU, S.; AVDAN, U. Monitoring the water quality of small water bodies using high-resolution remote sensing data. **ISPRS International Journal of Geo-Information**, v.8, n.12, December 2019. DOI. 10.3390/ijgi8120553.
- BARRETT, D.C.; FRAZIER, A.E. Automated method for monitoring water quality using Landsat imagery. **Water**, v.8, n.6, June 2016. DOI. 10.3390/w8060257.
- BINDING, C.; GREENBERG, T.; JEROME, J.; BUKATA, R.; LETOURNEAU, G. An assessment of MERIS algal products during an intense bloom in Lake of the Woods. **Journal of Plankton Research**, v.33, n.5, p.793-806, May 2011, DOI. 10.1093/plankt/fbq133.
- BINDING, C.; GREENBERG, T.; MCCULLOUGH, G.; WATSON, S.; PAGE, E. An analysis of satellite-derived chlorophyll and algal bloom indices on Lake Winnipeg. **Journal of Great Lakes Research**, v.44, n.3, p.436-446, June 2018. DOI. 10.1016/j.jglr.2018.04.001.
- BLIX, K.; PÁLFFY, K.; TÓTH, V.; ELTOFT, T. Remote sensing of water quality parameters over Lake Balaton by using Sentinel-3 OLCI. **Water**, v.10, n.10, October 2018, DOI. 10.3390/w10101428.
- BONANSEA, M.; BAZÁN, R.; LEDESMA, C.; RODRIGUEZ, C.; PINOTTI, L. Monitoring of regional lake water clarity using Landsat imagery. **Hydrology Research**, v.46, n.5, p.661-670, October 2015, DOI. 10.2166/nh.2014.211.
- BONANSEA, M.; RODRIGUEZ, C.; PINOTTI, L. Assessing the potential of integrating Landsat sensors for estimating chlorophyll-a concentration in a reservoir. **Hydrology Research**, v.49, n.5, p.1608-1617, October 2018. DOI. 10.2166/nh.2017.116.
- BRESCIANI, M.; CAZZANIGA, I.; AUSTONI, M.; SFORZI, T.; BUZZI, F.; MORABITO, G.; GIARDINO, C. Mapping phytoplankton blooms in deep subalpine lakes from Sentinel-2A and Landsat-8. **Hydrobiologia**, v.824, p.197-214, January 2018, DOI. 10.1007/s10750-017-3462-2.
- BRESCIANI, M.; PINARDI, M.; FREE, G.; LUCIANI, G.; GHEBREHIWOT, S.; LAANEN, M.; PETERS, S.; DELLA BELLA, V.; PADULA, R.; GIARDINO, C. The use of multisource optical sensors to study phytoplankton spatio-temporal variation in a shallow turbid lake. **Water**, v.12, n.1, January 2020. DOI. 10.3390/w12010284.
- CABALLERO, I.; NAVARRO, G. Monitoring cyanoHABs and water quality in Laguna Lake (Philippines) with Sentinel-2 satellites during the 2020 Pacific typhoon season. **Science of The Total Environment**, v.788, September 2021, DOI. 10.1016/j.scitotenv.2021.147700.

- CAO, Z.; MA, R.; DUAN, H.; XUE, K.; SHEN, M. Effect of satellite temporal resolution on long-term suspended particulate matter in inland lakes. **Remote Sensing**, v.11, n.23, November 2019. DOI. 10.3390/rs11232785.
- CGLS – Copernicus Global Land Service. **Lake Water Quality**. Available at: <<https://land.copernicus.eu/global/products/lwq>>. Accessed in: 20 Dec. 2021.
- CHEN, F.; WU, G.; WANG, J.; HE, J.; WANG, Y. A MODIS-based retrieval model of suspended particulate matter concentration for the two largest freshwater lakes in China. **Sustainability**, v.8, n.8, August 2016. DOI. 10.3390/su8080832.
- CHENG, C.; WEI, Y.; LV, G.; YUAN, Z. Remote estimation of chlorophyll-a concentration in turbid water using a spectral index: a case study in Taihu Lake, China. **Journal of Applied Remote Sensing**, v.7, n.1, December 2013. DOI. 10.1117/1.JRS.7.073465.
- COELHO, C.; HEIM, B.; FOERSTER, S.; BROSINSKY, A.; ARAÚJO, J.C. In situ and satellite observation of CDOM and chlorophyll-a dynamics in small water surface reservoirs in the Brazilian semiarid region. **Water**, v.9, n.12, December 2017. DOI. 10.3390/w9120913.
- COELHO, L.S.; ROCHE, K.F.; PARANHOS FILHO, A.C.; LEMOS, V.B. Uso do sensor CBERS/CCD na avaliação do estado trófico do Reservatório Lago do Amor (Campo Grande, MS). **Revista Brasileira de Cartografia**, v.63, n.2, p.221-232, 2011.
- CUI, L.; QIU, Y.; FEI, T.; LIU, Y.; WU, G. Using remotely sensed suspended sediment concentration variation to improve management of Poyang Lake, China. **Lake and Reservoir Management**, v.29, n.1, p.47-60, February 2013. DOI. 10.1080/10402381.2013.768733.
- CURTARELLI, M.; ALCÂNTARA, E.; RENNÓ, C.; STECH, J. Physical changes within a large tropical hydroelectric reservoir induced by wintertime cold front activity. **Hydrology and Earth System Sciences**, v.18, n.8, p.3079-3093, August 2014. DOI. 10.5194/hess-18-3079-2014.
- DOXANI, G.; VERMOTE, E.; ROGER, J.C.; GASCON, F.; ADRIAENSEN, S.; FRANTZ, D.; HAGOLLE, O.; HOLLSTEIN, A.; KIRCHES, G.; LI, F.; LOUIS, J.; MANGIN, A.; PALEVAN, N.; PFLUG, B.; VANHELLEMONT, Q. Atmospheric correction inter-comparison exercise. **Remote Sensing**, v.10, n.2, February 2018. DOI. 10.3390/rs10020352.
- ELHAG, M.; GITAS, I.; OTHMAN, A.; BAHRAWI, J.; GIKAS, P. Assessment of water quality parameters using temporal remote sensing spectral reflectance in arid environments, Saudi Arabia. **Water**, v.11, n.3, March 2019. DOI. 10.3390/w11030556.
- EUGENIO, F.; MARCELLO, J.; MARTÍN, J. Multiplatform earth observation systems for monitoring water quality in vulnerable inland ecosystems: Maspalomas Water Lagoon. **Remote Sensing**, v.12, n.2, January 2020. DOI. 10.3390/rs12020284.
- FACCO, D.S.; GUASSELLI, L.A.; RUIZ, L.F.C.; SIMIONI, J.P.D.; DICK, D.G. Spectral reflectance in the spatial-temporal dynamic of turbidity, Itaipu Reservoir, Brazil. **Anuário do Instituto de Geociências**, v.44, n.41228, 2021. DOI. 10.11137/1982-3908_2021_44_41228.
- FERREIRA, M.S.; GALO, M.L.B. Chlorophyll a spatial inference using artificial neural network from multispectral images and in situ measurements. **Anais da Academia Brasileira de Ciências**, v.85, n.2, p.519-532, June 2013. DOI. 10.1590/S0001-37652013005000037.
- FLORES-ANDERSON, A.I.; GRIFFIN, R.; DIX, M.; ROMERO-OLIVA, C.S.; OCHAETA, G.; SKINNER-ALVARADO, J.; RAMIREZ MORAN, M.V.; HERNANDEZ, B.; CHERRINGTON, E.; PAGE, B.; BARRENO, F. Hyperspectral satellite remote sensing of water quality in Lake Atitlán, Guatemala. **Frontiers in Environmental Science**, v.8, February 2020. DOI. 10.3389/fenvs.2020.00007.
- GHOLIZADEH, M.H.; MELESSE, A.M.; REDDI, L. A comprehensive review on water quality parameters estimation using remote sensing techniques. **Sensors**, v.16, n.8, August 2016. DOI. 10.3390/s16081298.
- GIARDINO, C.; BRESCIANI, M.; CAZZANIGA, I.; SCHENK, K.; RIEGER, P.; BRAGA, F.; MATTA, E.; BRANDO, V.E. Evaluation of multi-resolution satellite sensors for assessing water quality and bottom depth of Lake Garda. **Sensors**, v.14, n.12, p.24116-24131, December 2014. DOI. 10.3390/s141224116.

- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, v.202, p.18-27, December 2017. DOI. 10.1016/j.rse.2017.06.031.
- HA, N.T.T.; THAO, N.T.P.; KOIKE, K.; NHUAN, M.T. Selecting the best band ratio to estimate chlorophyll-a concentration in a tropical freshwater lake using Sentinel 2A images from a case study of Lake Ba Be (Northern Vietnam). **ISPRS International Journal of Geo-Information**, v.6, n.9, September 2017. DOI. 10.3390/ijgi6090290.
- HAFEEZ, S.; WONG, M.S.; HO, H.C.; NAZEER, M.; NICHOL, J.; ABBAS, S.; TANG, D.; LEE, K.H.; PUN, L. Comparison of machine learning algorithms for retrieval of water quality indicators in case-II waters: a case study of Hong Kong. **Remote Sensing**, v.11, n.6, p.617, March 2019. DOI. 10.3390/rs11060617.
- HANSEN, C.H.; WILLIAMS, G.P. Evaluating remote sensing model specification methods for estimating water quality in optically diverse lakes throughout the growing season. **Hydrology**, v.5, n.4, November 2018, DOI. 10.3390/hydrology5040062.
- HEAL, K.V.; BARTOSOVA, A.; HIPSEY, M.R.; CHEN, X.; BUYTAERT, W.; LI, H.Y.; MCGRANE, S.J.; GUPTA, A.B.; CUDENNEC, C. Water quality: the missing dimension of water in the water-energy-food nexus. **Hydrological Sciences Journal**, v.66, n.5, p.745-758, March 2021. DOI. 10.1080/02626667.2020.1859114.
- HUO, A.; ZHANG, J.; QIAO, C.; LI, C.; XIE, J.; WANG, J.; ZHANG, X. Multispectral remote sensing inversion for city landscape water eutrophication based on genetic algorithm-support vector machine. **Water Quality Research Journal of Canada**, v.49, n.3, p.285-293, August 2014. DOI. 10.2166/wqrjc.2014.040.
- JENSEN, J.R. **Introductory digital image processing**: a remote sensing perspective. 3ed. Upper Saddle River: Prentice-Hall, 2005
- KIM, Y.H.; IM, J.; HA, H.K.; CHOI, J.K.; HA, S. Machine learning approaches to coastal water quality monitoring using GOFCI satellite data. **GIScience & Remote Sensing**, v.51, n.2, p.158-174, April 2014. DOI. 10.1080/15481603.2014.900983.
- KNIGHT, J.F.; VOTH, M.L. Application of MODIS imagery for intra-annual water clarity assessment of Minnesota lakes. **Remote Sensing**, v.4, n.7, p.2181-2198, July 2012. DOI. 10.3390/rs4072181.
- KUMAR, L.; MUTANGA, O. Google Earth Engine applications since inception: usage, trends, and potential. **Remote Sensing**, v.10, n.10, September 2018. DOI. doi.org/10.3390/rs10101509.
- KUPSSINSKÜ, L.S.; GUIMARÃES, T.T.; SOUZA, E.M.; ZANOTTA, D.C.; VERONEZ, M.R.; GONZAGA, L.; MAUAD, F.F. A method for chlorophyll-a and suspended solids prediction through remote sensing and machine learning. **Sensors**, v.20, n.7, April 2020. DOI. 10.3390/s20072125.
- LARY, D.J.; ALAVI, A.H.; GANDOMI, A.H.; WALKER, A.L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v.7, n.1, p.3-10, January 2016. DOI. 10.1016/j.gsf.2015.07.003.
- LI, X.; HUANG, M.; WANG, R. Numerical simulation of Donghu Lake hydrodynamics and water quality based on remote sensing and MIKE 21. **ISPRS International Journal of Geo-Information**, v.9, n.2, February 2020. DOI. doi.org/10.3390/ijgi9020094.
- LI, Y.; TIAN, L.; LI, W.; LI, J.; WEI, A.; LI, S.; TONG, R. Design and experiments of a water color remote sensing-oriented unmanned surface vehicle. **Sensors**, v.20, n.8, April 2020. DOI. 10.3390/s20082183.
- LI, Y.; ZHANG, Q.; ZHANG, L.; TAN, Z.; YAO, J. Investigation of water temperature variations and sensitivities in a large floodplain lake system (Poyang Lake, China) using a hydrodynamic model. **Remote Sensing**, v.9, n.12, November 2017. DOI. 10.3390/rs9121231.
- LIN, S.; NOVITSKI, L.N.; QI, J.; STEVENSON, R.J. Landsat TM/ETM+ and machine-learning algorithms for limnological studies and algal bloom management of inland lakes. **Journal of Applied Remote Sensing**, v.12, n.2, April 2018. DOI. 10.1117/1.JRS.12.026003.
- LIU, D.; DUAN, H.; LOISELLE, S.; HU, C.; ZHANG, G.; LI, J.; YANG, H.; THOMPSON, J.R.; CAO, Z.; SHEN, M.; MA, R.; ZHANG, M.; HAN, W. Observations of water transparency in China's lakes from

- space. **International Journal of Applied Earth Observation and Geoinformation**, v.92, October 2020. DOI. 10.1016/j.jag.2020.102187.
- LIU, J.; ZHANG, Y.; YUAN, D.; SONG, X. Empirical estimation of total nitrogen and total phosphorus concentration of urban water bodies in China using high resolution IKONOS multispectral imagery. **Water**, v.7, n.11, p.6551-6573, November 2015. DOI. 10.3390/w7116551.
- LIU, X.; LEE, Z.; ZHANG, Y.; LIN, J.; SHI, K.; ZHOU, Y.; QIN, B.; SUN, Z. Remote sensing of Secchi depth in highly turbid lake waters and its application with MERIS data. **Remote Sensing**, v.11, n.19, September 2019. DOI. 10.3390/rs11192226.
- LIU, Y.; ISLAM, M.A.; GAO, J. Quantification of shallow water quality parameters by means of remote sensing. **Progress in Physical Geography**, v.27, n.1, p.24-43, March 2003. DOI. 10.1191/0309133303pp357ra.
- LOBO, F.L.; NAGEL, G.W.; MACIEL, D.A.; CARVALHO, L.A.S.; MARTINS, V.S.; BARBOSA, C.C.F.; NOVO, E.M.L.M. AlgaeMAP: Algae bloom monitoring application for inland waters in Latin America. **Remote Sensing**, v.13, n.15, July 2021. DOI. 10.3390/rs13152874.
- LUZ, G.A.; GUASSELLI, L.A.; ROCHA, D. Temperature surface of Guaíba Lake, RS, from time series of MODIS images. **Revista Brasileira de Recursos Hídricos**, v.22, n.17, November 2016. DOI. 10.1590/2318-0331.011716094.
- MACIEL, D.A.; BARBOSA, C.C.F.; NOVO, E.M.L.M.; FLORES-JÚNIOR, R.F.; BEGLIOMINI, F.N. Water clarity in Brazilian water assessed using Sentinel-2 and machine learning methods. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.182, p.134-152, December 2021. DOI. 10.1016/j.isprsjprs.2021.10.009.
- MALAHLELA, O.E.; OLIPHANT, T.; TSOELENG, L.T.; MHANGARA, P. Mapping chlorophyll-a concentrations in a cyanobacteria- and algae-impacted Vaal Dam using Landsat 8 OLI data. **South African Journal of Science**, v.114, n.9/10, p.1-9, September/October 2018. DOI. 10.17159/sajs.2018/4841.
- MANCINO, G., NOLÈ, A., URBANO, V., AMATO, M., FERRARA, A., 2009. Assessing water quality by remote sensing in small lakes: the case study of Monticchio lakes in southern Italy. **iForest-Biogeosciences and Forestry**, v.2, n.1, p.154-161, July 2009. DOI. 10.3832/ifor0507-002.
- MARKELIN, L.; SIMIS, S.G.; HUNTER, P.D.; SPYRAKOS, E.; TYLER, A.N.; CLEWLEY, D.; GROOM, S. Atmospheric correction performance of hyperspectral airborne imagery over a small eutrophic lake under changing cloud cover. **Remote Sensing**, v.9, n.1, January 2017. DOI. 10.3390/rs9010002.
- MARKERT, K.N.; SCHMIDT, C.M.; GRIFFIN, R.E.; FLORES, A.I.; POORTINGA, A.; SAAH, D.S.; MUENCH, R.E.; CLINTON, N.E.; CHISHTIE, F.; KITYUTTACHAI, K. SOMETH, P.; ANDERSON, E.; AEKAKKARARUNGROJ, A.; GANZ, D. Historical and operational monitoring of surface sediments in the lower Mekong Basin using Landsat and Google Earth Engine cloud computing. **Remote Sensing**, v.10, n.6, June 2018. DOI. 10.3390/rs10060909.
- MARKOGIANNI, V.; KALIVAS, D.; PETROPOULOS, G.P.; DIMITRIOU, E. An appraisal of the potential of Landsat 8 in estimating chlorophyll-a, ammonium concentrations and other water quality indicators. **Remote Sensing**, v.10, n.7, June 2018. DOI. 10.3390/rs10071018.
- MENKEN, K.D.; BREZONIK, P.L.; BAUER, M.E. Influence of chlorophyll and colored dissolved organic matter (CDOM) on lake reflectance spectra: Implications for measuring lake properties by remote sensing. **Lake and Reservoir Management**, v.22, n.3, p.179-190, 2006. DOI. 10.1080/07438140609353895.
- MERTES, L.A.; DEKKER, A.; BRAKENRIDGE, G.; BIRKETT, C.; LETOURNOU, G. Rivers and lakes. In: USTIN, S.L. (Ed.). **Remote sensing for natural resource management and environmental monitoring**. 3ed. New York: John Wiley and Sons, 2004. p.345-400.
- MISHRA, M.K.; RATHORE, P.S.; MISRA, A.; KUMAR, R. Atmospheric correction of multi-spectral VNIR remote sensing data: Algorithm and inter-sensor comparison of aerosol and surface reflectance products. **Earth and Space Science**, v.7, n.9, April 2020. DOI. 10.1029/2019EA000710.
- MISHRA, S.; MISHRA, D. A novel remote sensing algorithm to quantify phycocyanin in cyanobacterial algal

- blooms. **Environmental Research Letters**, v.9, n.11, November 2014. DOI. 10.1088/1748-9326/9/11/114003.
- NEIL, C.; SPYRAKOS, E.; HUNTER, P.D.; TYLER, A.N. A global approach for chlorophyll-a retrieval across optically complex inland waters based on optical water types. **Remote Sensing of Environment**, v.229, p.159-178, August 2019. DOI. 10.1016/j.rse.2019.04.027.
- NOVO, E.M.L.M.; LONDE, L.R.; BARBOSA, C.; ARAUJO, C.A.; RENNÓ, C.D. Proposal for a remote sensing trophic state index based upon Thematic Mapper/Landsat images. **Revista Ambiente & Água**, v.8, n.3, p.65-82, December 2013. DOI. 10.4136/1980-993X.
- ODERMATT, D.; DANNE, O.; PHILIPSON, P.; BROCKMANN, C. Diversity II water quality parameters from ENVISAT (2002-2012): a new global information source for lakes. **Earth System Science Data**, v.10, n.3, August 2018. DOI. 10.5194/essd-10-1527-2018.
- ODERMATT, D.; HEEGE, T.; NIEKE, J.; KNEUBÜHLER, M.; ITTEN, K. Water quality monitoring for Lake Constance with a physically based algorithm for MERIS data. **Sensors**, v.8, n.8, p.4582-4599, August 2008. DOI. 10.3390/s8084582.
- OGASHAWARA, I. The use of Sentinel-3 imagery to monitor cyanobacterial blooms. **Environments**, v.6, n.6, June 2019. DOI. 10.3390/environments6060060.
- OGASHAWARA, I.; ALCÂNTARA, E.H.; CURTARELLI, M.P.; ADAMI, M.; NASCIMENTO, R.F.; SOUZA, A.F.; STECH, J.L.; KAMPEL, M. 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 Sensing**, v.6, n.2, p.1634-1653, February 2014a, DOI. 10.3390/rs6021634.
- OGASHAWARA, I.; ALCÂNTARA, E.H.; STECH, J.L.; TUNDISI, J.G. Cyanobacteria detection in Guarapiranga Reservoir (São Paulo state, Brazil) using Landsat TM and ETM+ images. **Revista Ambiente & Água**, v.9, p.224-238, June 2014b. DOI. 10.4136/ambi-agua.1327.
- OGASHAWARA, I.; MORENO-MADRÍNÁN, M.J. Improving inland water quality monitoring through remote sensing techniques. **ISPRS International Journal of Geo-Information**, v.3, n.4, p.1234-1255, November 2014. DOI. 10.3390/ijgi3041234.
- PAGE, B.P.; OLMANSON, L.G.; MISHRA, D.R. A harmonized image processing workflow using Sentinel-2/MSI and Landsat-8/OLI for mapping water clarity in optically variable lake systems. **Remote Sensing of Environment**, v.231, September 2019. DOI. 10.1016/j.rse.2019.111284.
- PAHLEVAN, N.; SMITH, B.; SCHALLES, J.; BINDING, C.; CAO, Z.; MA, R.; ALIKAS, K.; KANGRO, K.; GURLIN, D.; HÀ, N.; MATSUSHITA, B.; MOSES, W.; GREB, S.; LEHMANN, K.; ONDRUSEK, M.; OPPELT, N.; STUMPF, R. Seamless retrievals of chlorophyll-a from Sentinel-2 (MSI) and Sentinel-3 (OLCI) in inland and coastal waters: A machine-learning approach. **Remote Sensing of Environment**, v.240, April 2020. DOI. 10.1016/j.rse.2019.111604.
- PALMER, S.C.; HUNTER, P.D.; LANKESTER, T.; HUBBARD, S.; SPYRAKOS, E.; TYLER, A.N.; PRESING, M.; HORVATH, H.; LAMB, A.; BALZTER, H.; TÓTH, V. Validation of Envisat MERIS algorithms for chlorophyll retrieval in a large, turbid and optically-complex shallow lake. **Remote Sensing of Environment**, v.157, p.158-169, February 2015a. DOI. 10.1016/j.rse.2014.07.024.
- PALMER, S.C.; ODERMATT, D.; HUNTER, P.; BROCKMANN, C.; PRESING, M.; BALZTER, H.; TÓTH, V. Satellite remote sensing of phytoplankton phenology in Lake Balaton using 10 years of MERIS observations. **Remote Sensing of Environment**, v.158, p.441-452, March 2015b. DOI. 10.1016/j.rse.2014.11.021.
- PEPPA, M.; VASILAKOS, C.; KAVROUDAKIS, D. Eutrophication monitoring for Lake Pamvotis, Greece, using Sentinel-2 data. **ISPRS International Journal of Geo-Information**, v.9, n.3, February 2020. DOI. 10.3390/ijgi9030143.
- PHILIPSON, P.; KRATZER, S.; BEN MUSTAPHA, S.; STRÖMBERCK, N.; STELZER, K. Satellite-based water quality monitoring in Lake Vänern, Sweden. **International Journal of Remote Sensing**, v.37, n.16, p.3938-3960, July 2016. DOI. 10.1080/01431161.2016.1204480.

- PINARDI, M.; FENOCCHI, A.; GIARDINO, C.; SIBILLA, S.; BARTOLI, M.; BRESCIANI, M. Assessing potential algal blooms in a shallow fluvial lake by combining hydrodynamic modelling and remote-sensed images. *Water*, v.7, n.5, p.1921-1942, April 2015. DOI. 10.3390/w7051921.
- PIZANI, F.M.; MAILLARD, P.; FERREIRA, A.F.; AMORIM, C.C. Estimation of water quality in a reservoir from Sentinel-2 MSI and Landsat-8 OLI sensors. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.3, p.401-408, August 2020. DOI. 10.5194/isprs-annals-V-3-2020-401-2020.
- POLITI, E.; CUTLER, M.E.; ROWAN, J.S. Evaluating the spatial transferability and temporal repeatability of remote-sensing-based lake water quality retrieval algorithms at the European scale: a meta-analysis approach. **International Journal of Remote Sensing**, v.36, n.11, p.2995-3023, June 2015. DOI. 10.1080/01431161.2015.1054962.
- POTES, M.; COSTA, M.J.; SALGADO, R. Satellite remote sensing of water turbidity in Alqueva Reservoir and implications on lake modelling. **Hydrology & Earth System Sciences**, v.16, n.6, p.1623-1633, June 2012. DOI. 10.5194/hess-16-1623-2012.
- PU, F.; DING, C.; CHAO, Z.; YU, Y.; XU, X. Water-quality classification of inland lakes using Landsat8 images by convolutional neural networks. **Remote Sensing**, v.11, n.14, p.1674, July 2019. DOI. 10.3390/rs11141674.
- PYO, J.C.; LIGARAY, M.; KWON, Y.S.; AHN, M.H.; KIM, K.; LEE, H.; KANG, T.; CHO, S.B.; PARK, Y.; CHO, K.H. High-spatial resolution monitoring of phycocyanin and chlorophyll-a using airborne hyperspectral imagery. **Remote Sensing**, v.10, n.8, p.1180, July 2018. DOI. 10.3390/rs10081180.
- QUANG, N.H.; SASAKI, J.; HIGA, H.; HUAN, N.H. Spatiotemporal variation of turbidity based on Landsat 8 OLI in Cam Ranh Bay and Thuy Trieu Lagoon, Vietnam. **Water**, v.9, n.8, p.570, August 2017. DOI. 10.3390/w9080570.
- READ, E.K.; CARR, L.; DE CICCO, L.; DUGAN, H.A.; HANSON, P.C.; HART, J.A.; KREFT, J.; READ, J.S.; WINSLOW, L.A. Water quality data for national-scale aquatic research: The Water Quality Portal. **Water Resources Research**, v.53, n.2, p.1735-1745, January 2017. DOI. 10.1002/2016WR019993.
- ROBERT, E.; KERGOAT, L.; SOUMAGUEL, N.; MERLET, S.; MARTINEZ, J.M.; DIAWARA, M.; GRIPPA, M. Analysis of suspended particulate matter and its drivers in Sahelian ponds and lakes by remote sensing (Landsat and MODIS): Gourma Region, Mali. **Remote Sensing**, v.9, n.12, p.1272, December 2017. DOI. 10.3390/rs9121272.
- RODRIGUES, T.; ALCÂNTARA, E.; WATANABE, F.; IMAI, N. Retrieval of Secchi disk depth from a reservoir using a semi-analytical scheme. **Remote Sensing of Environment**, v.198, p.213-228, September 2017. DOI. 10.1016/j.rse.2017.06.018.
- ROSMORDUC, V.; BENVENISTE, J.; BRONER, O.; DINARDO, S.; LAURET, O.; MILAGRO, M.; PICOT, N.; AMBROZIO, A.; ESCOLÀ, R.; GARCIA-MONDEJAR, A.; SCHRAMA, E.; RESTANO, M.; TERRA-HOMEM, M. **Radar Altimetry Tutorial**. October 2018. Available at: <<http://www.altimetry.info>>. Accessed in: 20 Dec. 2021.
- RUESCAS, A.B., HIERONYMI, M., MATEO-GARCIA, G., KOPONEN, S., KALLIO, K., CAMPS-VALLS, G. Machine learning regression approaches for colored dissolved organic matter (CDOM) retrieval with S2-MSI and S3-OLCI simulated data. **Remote Sensing**, v.10, n.5, p.786, May 2018. DOI. 10.3390/rs10050786.
- RUSSELL, S., NORVIG, P. Learning from observation. IN: Russell, S., Norvig, P. (Eds.). **Artificial intelligence: a modern approach**. New Jersey: Prentice Hall, 1995. p.525-562.
- SABAT-TOMALA, A.; JAROCINSKA, A.M.; ZAGAJEWSKI, B.; MAGNUSZEWSKI, A.S.; SLAWIK, L.M.; OCHTYRA, A.; RACZKO, E.; LECHNIO, J.R. Application of HySpex hyperspectral images for verification of a two-dimensional hydrodynamic model. **European Journal of Remote Sensing**, v.51, n.1, p.637-649, May 2018. DOI. 10.1080/22797254.2018.1470905.
- SAGAN, V.; PETERSON, K.T.; MAIMAITIJIANG, M.; SIDIKE, P.; SLOAN, J.; GREELING, B.A.;

- MAALOUF, S.; ADAMS, C. Monitoring inland water quality using remote sensing: potential and limitations of spectral indices, bio-optical simulations, machine learning, and cloud computing. **Earth-Science Reviews**, v.205, p.103187, June 2020. DOI. 10.1016/j.earscirev.2020.103187.
- SILVA, H.A.N.; NARANJO, P.G.V.; RODRIGUES, L.P.S.; ARAÚJO, D.M.; PIRES, Y.P. Prediction of some physico-chemical parameters of water in Alton Reservoir, Suffolk, England. **WSEAS Transactions on Environment and Development**, v.16, p.119-131, 2020. DOI. 10.37394/232015.2020.16.12.
- SOLA, I.; GARCÍA-MARTÍN, A.; SANDONÍS-POZO, L.; ÁLVAREZ-MOZOS, J.; PÉREZ-CABELLO, F.; GONZÁLEZ-AUDÍCANA, M.; LLOVERÍA, R.M. Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. **International Journal of Applied Earth Observation and Geoinformation**, v.73, p.63-76, December 2018. DOI. 10.1016/j.jag.2018.05.020.
- SON, S., WANG, M., 2019. VIIRS-Derived water turbidity in the Great Lakes. **Remote Sensing**, v.11, n.12, p.1448, June 2019. DOI. 10.3390/rs11121448.
- SOOMETS, T.; UUDEBERG, K.; JAKOVELS, D.; BRAUNS, A.; ZAGARS, M.; KUTSER, T. Validation and comparison of water quality products in Baltic lakes using Sentinel-2 MSI and Sentinel-3 OLCI data. **Sensors**, v.20, n.3, p.742, January 2020. DOI. 10.3390/s20030742.
- SÒRIA-PERPINYÀ, X.; VICENTE, E.; URREGO, P.; PEREIRA-SANDOVAL, M.; RUÍZ-VERDÚ, A.; DELEGIDO, J.; SORIA, J.M.; MORENO, J. Remote sensing of cyanobacterial blooms in a hypertrophic lagoon (Albufera of València, Eastern Iberian Peninsula) using multitemporal Sentinel-2 images. **Science of The Total Environment**, v.698, p.134305, January 2020. DOI. 10.1016/j.scitotenv.2019.134305.
- STEFOLI, M.; CHAROU, E. Monitoring of transnational lakes using geomatic techniques: a case study for Prespa lakes. **International Journal of Design & Nature and Ecodynamics**, v.7, n.2, p.199-209, 2012. DOI. 10.2495/DNE-V7-N2-199-209.
- TOMING, K.; KUTSER, T.; LAAS, A.; SEPP, M.; PAAVEL, B.; NÖGES, T. First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. **Remote Sensing**, v.8, n.8, p.640, August 2016. DOI. 10.3390/rs8080640.
- TOPP, S.N.; PAVELSKY, T.M.; JENSEN, D.; SIMARD, M.; ROSS, M.R.V. Research trends in the use of remote sensing for inland water quality science: Moving towards multidisciplinary applications. **Water**, v.12, n.1, p.169, January 2020. DOI. 10.3390/w12010169.
- TORBICK, N., CORBIERE, M. A multiscale mapping assessment of Lake Champlain cyanobacterial harmful algal blooms. **International Journal of Environmental Research and Public Health**, v.12, n.9, p.11560-11578, September 2015. DOI. 10.3390/ijerph120911560.
- TORBICK, N.; HESSION, S.; STOMMEL, E.; CALLER, T. Mapping amyotrophic lateral sclerosis lake risk factors across northern New England. **International Journal of Health Geographics**, v.13, n.1, January 2014. DOI. 10.1186/1476-072X-13-1.
- TORBICK, N.; ZINITI, B.; STOMMEL, E.; LINDER, E.; ANDREW, A.; CALLER, T.; HANEY, J.; BRADLEY, W.; HENEGAN, P.L.; SHI, X. Assessing cyanobacterial harmful algal blooms as risk factors for amyotrophic lateral sclerosis. **Neurotoxicity Research**, v.33, p.199-212, January 2018. DOI. 10.1007/s12640-017-9740-y.
- UNEP – UNITED NATIONS ENVIRONMENT PROGRAMME. Global Freshwater Quality Database GEMStat. Available at <<https://gemstat.org/>>. Accessed in: 20 Dec. 2021.
- UUDEBERG, K.; AAVASTE, A.; KÕKS, K.; ANSPER, A.; UUSÕUE, M.; KANGRO, K.; ANSKO, I.; LIGI, M.; TOMING, K.; REINART, A. Optical water type guided approach to estimate optical water quality parameters. **Remote Sensing**, v.12, n.6, p.931, March 2020. DOI. 10.3390/rs12060931.
- VAN DER MERWE, D.; PRICE, K.P. Harmful algal bloom characterization at ultra-high spatial and temporal resolution using small unmanned aircraft systems. **Toxins**, v.7, n.4, p.1065-1078, March 2015. DOI. 10.3390/toxins7041065.
- VAN NGUYEN, M.; LIN, C.H.; CHU, H.J.; JAELANI, L.M.; SYARIZ, M.A. Spectral feature selection optimization for water quality estimation. **International Journal of Environmental Research and**

Public Health, v.17, n.1, p.272, January 2020. DOI. 10.3390/ijerph17010272.

237

- VERONEZ, M.R.; KUPSSINSKÜ, L.S.; GUIMARÃES, T.T.; KOSTE, E.C.; SILVA, J.M.; SOUZA, L.V.; OLIVERIO, W.F.; JARDIM, R.S.; KOCH, I.É.; SOUZA, J.G.; GONZAGA JUNIOR, L.; MAUAD, F.F.; INOCENCIO, L.C.; BORDIN, F. Proposal of a method to determine the correlation between total suspended solids and dissolved organic matter in water bodies from spectral imaging and artificial neural networks. **Sensors**, v.18, n.1, p.159, January 2018. DOI. 10.3390/s18010159.
- VERSCHUUR, G.L. Transparency measurements in Garner Lake, Tennessee: the relationship between Secchi depth and solar altitude and a suggestion for normalization of Secchi depth data. **Lake and Reservoir Management**, v.13, n.2, p.142-153, 1997. DOI. 10.1080/07438149709354305.
- VUNDO, A.; MATSUSHITA, B.; JIANG, D.; GONDWE, M.; HAMZAH, R.; SETIAWAN, F.; FUKUSHIMA, T. An overall evaluation of water transparency in Lake Malawi from MERIS data. **Remote Sensing**, v.11, n.3, p.279, January 2019. DOI. 10.3390/rs11030279.
- WANG, D.; KAGEYAMA, Y.; NISHIDA, M.; SHIRAI, H. Algorithm to analyze water quality conditions of Lake Hachiroko using textures of JERS-1 SAR data. **International Journal of the Society of Materials Engineering for Resources**, v.18, n.2, p.51-58, March 2012. DOI. 10.5188/ijsmcr.18.51.
- WANG, D.; KAGEYAMA, Y.; NISHIDA, M.; SHIRAI, H.; KASAI, C. Water quality analysis of Lake Hachiroko, Japan, using ALOS PALSAR data. **International Journal of the Society of Materials Engineering for Resources**, v.20, n.2, p.175-180, October 2014. DOI. 10.5188/ijsmcr.20.175.
- WANG, L.; XU, M.; LIU, Y.; LIU, H.; BECK, R.; REIF, M.; EMERY, E.; YOUNG, J.; WU, Q. Mapping freshwater chlorophyll-a concentrations at a regional scale integrating multi-sensor satellite observations with Google Earth Engine. **Remote Sensing**, v.12, n.20, p.3278, October 2020. DOI. 10.3390/rs12203278.
- WATANABE, F.; ALCANTARA, E.; RODRIGUES, T.; ROTTA, L.; BERNARDO, N.; IMAI, N. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita Reservoir, Brazil). **Anais da Academia Brasileira de Ciências**, v.90, p.1987-2000, August 2018. DOI. 10.1590/0001-3765201720170125.
- WATANABE, F.S.Y.; ALCÂNTARA, E.; RODRIGUES, T.W.P.; IMAI, N.N.; BARBOSA, C.C.F.; ROTTA, L.H.S. Estimation of chlorophyll-a concentration and the trophic state of the Barra Bonita Hydroelectric Reservoir using OLI/Landsat-8 images. **International Journal of Environmental Research and Public Health**, v.12, n.9, p.10391-10417, August 2015. DOI. 10.3390/ijerph120910391.
- WILKIE, C.J.; MILLER, C.A.; SCOTT, E.M.; O'DONNELL, R.A.; HUNTER, P.D.; SPYRAKOS, E.; TYLER, A.N. Nonparametric statistical downscaling for the fusion of data of different spatiotemporal support. **Environmetrics**, v.30, n.3, May 2019. DOI. 10.1002/env.2549.
- XIANG, B.; SONG, J.W.; WANG, X.Y.; ZHEN, J. Improving the accuracy of estimation of eutrophication state index using a remote sensing data-driven method: A case study of Chaohu Lake, China. **Water SA**, v.41, n.5, p.753-761, October 2015. DOI. 10.4314/WSA.V41I5.18.
- XIONG, J. ; LIN, C. ; MA, R. ; CAO, Z. Remote sensing estimation of lake total phosphorus concentration based on MODIS: A case study of Lake Hongze. **Remote Sensing**, v.11, n.17, p.2068, September 2019. DOI. 10.3390/rs11172068.
- XU, X.; HUANG, X.; ZHANG, Y.; YU, D. Long-term changes in water clarity in Lake Liangzi determined by remote sensing. **Remote Sensing**, v.10, n.9, p.1441, September 2018. DOI. 10.3390/rs10091441.
- ZENG, C.; BINDING, C. The effect of mineral sediments on satellite chlorophyll-a retrievals from line-height algorithms using red and near-infrared bands. **Remote Sensing**, v.11, n.19, p.2306, October 2019. DOI. 10.3390/rs11192306.
- ZHANG, M.; HU, C.; CANNIZZARO, J.; ENGLISH, D.; BARNES, B.B.; CARLSON, P.; YARBRO, L. Comparison of two atmospheric correction approaches applied to modis measurements over north american waters. **Remote Sensing of Environment**, v.216, p.442-455, October 2018. DOI. 10.1016/j.rse.2018.07.012.
- ZHANG, Y.; LIU, X.; QIN, B.; SHI, K.; DENG, J.; ZHOU, Y. Aquatic vegetation in response to increased

eutrophication and degraded light cli- mate in Eastern Lake Taihu: Implications for lake ecological restoration. **Scientific Reports**, v.6, p.1-12, April 2016. DOI. 10.1038/srep23867.

ZHANG, Y.; WU, L.; REN, H.; DENG, L.; ZHANG, P. Retrieval of water quality parameters from hyperspectral images using Hybrid Bayesian Probabilistic Neural Network. **Remote Sensing**, v.12, n.10, p.1567, May 2020. DOI. 10.3390/rs12101567.

ZHAO, Y.; SHEN, Q.; WANG, Q.; YANG, F.; WANG, S.; LI, J.; ZHANG, F.; YAO, Y. Recognition of water colour anomaly by using hue angle and Sentinel 2 image. **Remote Sensing**, v.12, n.4, p.716, February 2020. DOI. 10.3390/rs12040716.

First author biography



Fernanda Mara Coelho Pizani was born in Belo Horizonte-MG, Brazil, in 1986. She has a bachelor's degree in Geography from the Pontifical Catholic University of Minas Gerais (PUC-MG), and a master's degree in Analysis and Modeling of Environmental Systems from the Federal University of Minas Gerais (UFMG). She is currently a PhD candidate at the same institution and her research involves remote sensing applied to water quality.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](#) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.

ANEXO F – Artigo: Um índice de turbidez para águas relativamente claras

PIZANI, F.M.C.; MAILLARD, P.; AMORIM, C.C.. Um índice de turbidez para águas relativamente claras. In: Simpósio Brasileiro de Sensoriamento Remoto, 2023, Florianópolis. XX Simpósio Brasileiro de Sensoriamento Remoto, 2023. p. 1-4.

UM ÍNDICE DE TURBIDEZ PARA ÁGUAS RELATIVAMENTE CLARAS A TURBIDITY INDEX FOR RELATIVELY CLEAR WATERS

Fernanda Mara Coelho Pizani¹, Philippe Maillard²

¹Universidade Federal de Minas Gerais, Av. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, fm.coelho@yahoo.com.br, ²Universidade Federal de Minas Gerais, Av. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, philippermaillard@yahoo.com.br

RESUMO

Parâmetros de qualidade da água em reservatórios são tipicamente mensurados *in situ* podendo gerar altos custos à agência responsável. O sensoriamento remoto permite a redução dos custos na estimativa dos indicadores ópticos de qualidade da água, como a turbidez. Em ambientes de águas claras, esta estimativa pode ser um desafio. Para este caso foi desenvolvido um índice de turbidez mais sensível que o tradicional Índice de Turbidez de Diferença Normalizada (NDTI). Enquanto o NTDI alcançou um r^2 de 0,63, o novo índice chamado Índice de Turbidez Baixa de Diferença Normalizada (ITBDN) atingiu 0,77. Além disso, enquanto o NDTI produziu uma relação negativa, o ITBDN é positivo e relativamente mais estável em diversas situações. O Reservatório Três Marias/MG é utilizado como área teste.

Palavras-chave – Qualidade da Água, Índice de Turbidez, Reservatório, Análise de Regressão.

ABSTRACT

Water quality parameters in reservoirs are typically measured in situ and can generate high costs for the responsible agency. Remote sensing allows cost reduction in the estimation of optically active water quality parameters, such as turbidity. In clear water environments, this estimation can be challenging. For this case, we developed a more sensitive turbidity index than the traditional Normalized Difference Turbidity Index (NDTI). While the NTDI managed a r^2 of 0.63, the new index called the Normalized Difference Low Turbidity Index (NDLTI) reached 0.77. Furthermore, while the NDTI produced a negative relationship, the NDLTI is positive and relatively more stable in diverse situations. The Três Marias Reservoir/MG is used as a test area.

Key words – Water Quality, Turbidity Index, Reservoir, Regression Analysis.

1. INTRODUÇÃO

É estimado que o mundo contenha aproximadamente 16,7 milhões de reservatórios maiores que 0,01 ha, o que representa uma capacidade de 8070 km³ e uma área total de 305 000 km² [1]. Os reservatórios estão situados em uma posição intermediária entre os ambientes lóticos e lênticos e, de acordo com a dinâmica específica de cada um, podem ser considerados ambientes semi-fluviais com ecossistemas aquáticos contínuos [2].

O represamento de corpos d'água visa atender diversos objetivos, entre eles, abastecimento humano, atividades econômicas e lazer. Para que esses usos sejam atendidos de forma plena faz-se necessário controlar e preservar a qualidade da água destes ambientes represados. Os fatores que ocasionam impactos negativos à qualidade da água exigem a prática de ações mitigadoras a fim de garantir sua preservação, o que inclui a necessidade de controle da qualidade da água [3]. Este controle pode ser realizado por meio dos chamados indicadores ou parâmetros de qualidade da água, essencial para a gestão do recurso hídrico.

Tradicionalmente, os parâmetros de qualidade da água são mensurados *in situ* por meio de sondas paramétricas ou coletas amostrais associadas a análises de laboratório. No entanto, esta técnica é dispendiosa e inviável para muitos órgãos, o que pode ocasionar frequência amostral insuficiente. Neste sentido, o sensoriamento representa uma forma eficiente de monitorar a qualidade das águas superficiais em várias escalas de tempo e espaço [4].

Sensores a bordo de satélites captam por meio de imagens os efeitos da relação entre a radiação solar refletida (nos processos de absorção e espalhamento) e os constituintes presentes na água e fornecem informações espetrais que servem como subsídio para quantificar determinados parâmetros de qualidade da água. As alterações observadas nas propriedades ópticas da água são função de sua resposta espectral provenientes dos efeitos da interação dos componentes da água com a radiação solar e permite que esses componentes opticamente ativos (COAs) sejam usados como indicadores de qualidade da água [5].

O Reservatório Três Marias (Região Central de Minas Gerais), é uma represa sob a concessão da Companhia Energética de Minas Gerais (CEMIG). Apresenta 1090 km² de área e um volume de 21 km³. As atividades com maior potencial poluidor que impactam o Rio São Francisco por meio dos afluentes do Reservatório Três Marias são a mineração, a agricultura e a ocupação urbana, onde os principais poluentes advém de metais, pesticidas e excesso de nutrientes [6]. No entanto, o reservatório possui ambiente com características de águas claras [7], sendo considerado de águas complexas do Caso 2, fatores que dificultam a caracterização óptica do ambiente considerando a variação espacial irregular dos COAs [8]. Em ambientes de águas turvas, a resposta radiométrica da região espectral do vermelho é significativamente maior do que na região do verde (em função do material particulado em suspensão) fazendo com que sua relação seja inversa, fato que justifica o uso do Índice de Turbidez de Diferença Normalizada (*Normalized Difference Turbidity Index – NDTI* $\frac{\rho_{650}-\rho_{550}}{\rho_{665}+\rho_{560}}$) que usa a relação vermelho-verde como indicador [9].

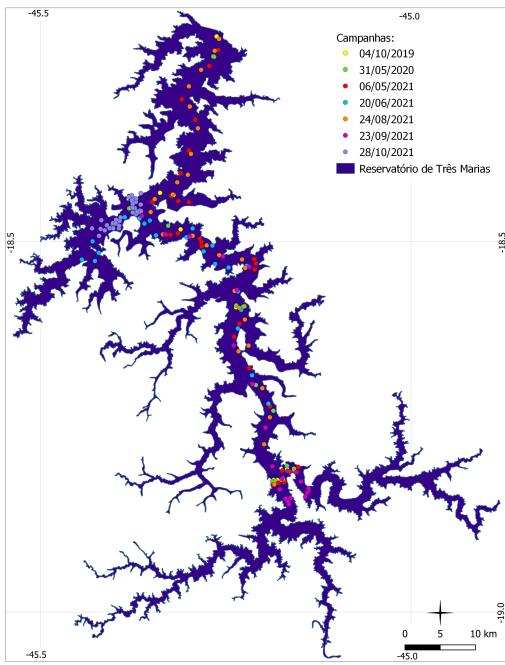


Figura 1: Distribuição dos pontos amostrais por campanha.

Nesse sentido, este estudo visou desenvolver um índice de turbidez para o Reservatório Três Marias, um ambiente de águas interiores essencialmente claras, utilizando técnicas de sensoriamento remoto. Para tanto, foram utilizadas imagens ópticas provenientes do sensor MSI acoplado ao Sentinel-2.

2. MATERIAL E MÉTODOS

2.1. Aquisição dos dados

Para aquisição dos dados limnológicos, foram realizadas oito campanhas de campo no Reservatório Três Marias entre os anos de 2019 e 2021 contabilizando um total de 168 pontos amostrais (Figura 1). A medição da turbidez se efetuou por meio da utilização de uma sonda multiparâmetros (EXO2 YSI) que permite a mensuração por nefelometria (FNU).

Foram utilizada imagens provenientes do sensor MSI dos satélites Sentinel-2 (A/B). As imagens foram adquiridos pelo portal PEPS (*Plateforme d'Exploitation des Produits Sentinel*) em nível 2A. A área de estudo está incluída na cena do Sentinel-2/MSI que corresponde à zona UTM 23 Sul, latitude K, faixa MV (23K MV).

Em todas as datas, o sobrevoo do Sentinel-2 efetuou-se às 10:17 AM diferenciando-se, entre datas, por segundos. O planejamento dos campos realizou-se de forma a possibilitar a sincronia entre a coleta dos dados *in situ* e a passagem do satélite com diferença de no máximo 4 horas. As imagens correspondentes aos períodos possuíam cobertura irrigária de nuvens acima do espelho d'água (abaixo de 5%) além de não haver interferências atmosféricas identificáveis.

2.2. Processamento dos dados

Os dados foram processados em nível 2A e utilizaram o algoritmo MAJA (MACCS ATCOR Joint Algorithm [10]) para a correção atmosférica. As bandas do Sentinel-2 Nível-

2 apresentam fator de escala de 0,0001, o que permite a conversão das bandas para reflectância por álgebra simples.

Uma vez que a área de pesquisa se restringe ao Reservatório Três Marias, os pixels correspondentes às porções de terra foram excluídos do estudo, limitando a análise ao espelho d'água da represa. Para tanto, os pixels de água foram extraídos das imagens de satélite por meio do Índice de Diferença Normalizada da Água (NDWI), proposto por McFeeters [11]. O índice utiliza a banda verde e a banda NIR, de acordo com a Equação $\frac{\rho_{560} - \rho_{842}}{\rho_{560} + \rho_{842}}$. O NDWI varia entre -1 e 1 e valores abaixo de 0 são classificados como “não água” e acima de 0 corresponde à classe “água” [12].

A fim de simplificar a extração de dados espectrais e aproveitar as 10 bandas de resolução fina, a construção dos modelos estatísticos foram construídos usando as bandas Sentinel-2 com resolução espacial de 20 m.

2.3. Modelagem óptica, validação e avaliação da acurácia

Foram avaliadas todas as bandas espectrais por meio de análise de regressão linear simples com o auxílio do software RStudio (v. 1.5.5109) a fim de calcular o coeficiente de determinação entre a turbidez e os valores de reflectância onde os pontos foram amostrados *in situ*. Além das bandas espectrais, utilizou-se o modelo NDTI de Lacaux *et al.* [9] como umas das variáveis a fim de comparar os resultados para este ambiente. O novo índice foi idealizado como uma forma de estimar a turbidez de ambientes lênticos e semi-lênticos com águas moderadamente claras, uma vez que o NDTI de Lacaux *et al.* [9], no geral, responde melhor em águas turvas.

A performance dos modelos foi avaliada a partir das seguintes métricas estatísticas: Coeficiente de Determinação Ajustado (r^2), Erro Médio Absoluto (MAE), Raiz do Erro Médio Quadrático (RMSE) e Raiz do Erro Médio Quadrático Normalizado (NRMSE). Com essa abordagem, pretende-se determinar quais bandas espectrais têm o melhor potencial para formação de um índice para águas de baixa turbidez.

3. RESULTADOS E DISCUSSÃO

O comportamento espectral da água do Reservatório Três Marias nos 168 pontos é ilustrado na Figura 2. Cada linha representa a reflectância em cada uma das 10 bandas espectrais do S-2. Com base em todas as campanhas, foram constatados picos de reflectância na região do verde (≈ 560 nm) onde a presença de sedimentos em suspensão contribui com o aumento da reflectância em todos os comprimentos de onda, mas não especialmente no vermelho como pressupõe o NDTI de Lacaux *et al.* [9]. No Reservatório Três Marias, observa-se o contrário: no geral, há um decréscimo da intensidade a medida que aumenta o comprimento de onda depois do verde. Nas diversas tentativas de registro do total de sólidos em suspensão pela sonda EXO2, nenhuma campanha obteve valores passíveis de mensuração acima do limite de detecção.

A água limpa manifesta reflectância espectral muito baixa, apresentando taxas em torno de 4% [13]. Assume-se que a absorção de luz na região do infravermelho se aproxima de zero em águas pouco turvas [5]. Os pontos amostrados nas diferentes épocas e em variadas regiões do reservatório não

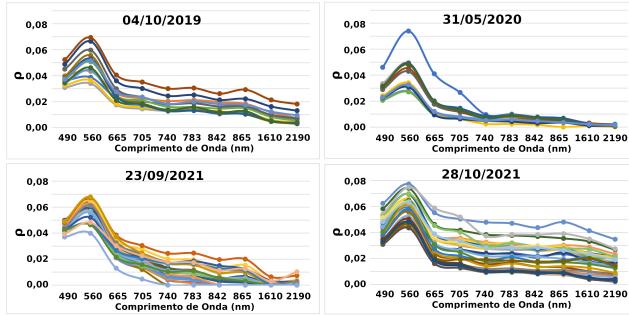


Figura 2: Comportamento espectral da água de Três Marias nos pontos mensurados em 4 das 7 campanhas de campo.

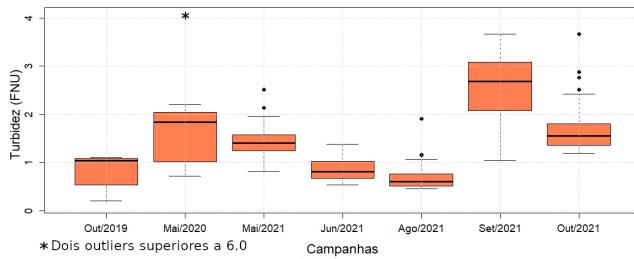


Figura 3: Variação da turbidez para as campanhas de campo.

ultrapassaram o valor de 8% de reflectância espectral, o que reforça a característica de um reservatório como um ambiente de águas claras e moderadamente claras.

O boxplot na Figura 3 mostra o intervalo referente ao índice de turbidez obtido durante os campo realizados em sete campanhas. Em geral, os índices menos elevados de turbidez do Reservatório Três Marias foram registrados próximo ao barramento. As duas últimas campanhas não mensuraram a turbidez nas proximidades da barragem. Os índices mais altos são valores de *outliers* registrados na campanha de maio de 2020 (≈ 6 FNU). Desconsiderando os *outliers*, percebe-se nas campanhas de maio, junho, agosto e outubro de 2021 uma distribuição homogênea dos valores de turbidez abaixo de 2 FNU.

Após verificar o comportamento espectral na área de estudo, foram testadas todas as bandas espectrais disponíveis no sensor MSI com resolução espacial de 20 m e o NDTI. Para efetuar os testes, utilizou-se o conjunto total de dados amostrados para turbidez (7 campanhas de campo para um total de 168 pontos amostrais, todos adquiridos com menos de 4 horas da passagem do satélite). Na regressão simples, foi extraído o valor do pixel de 20 m referente ao ponto amostrado. Os resultados das análises estatísticas para todo o conjunto de dados são apresentados na Tabela 1.

O objetivo dessa etapa foi comparar o desempenho de cada modelo separadamente. Em relação às faixas espectrais, os resultados mostram que a medida em que o comprimento de onda aumenta, o desempenho do modelo diminui consideravelmente. Pela análise da Tabela 1 utilizando o conjunto total de dados é possível verificar que o melhor desempenho é provido pelas bandas espectrais da faixa do visível (B3, B2 e B4, respectivamente). Fazendo uso da banda única B3, o coeficiente de determinação atingiu 0,81. As bandas espectrais B2 e B4 apresentaram resultado similar ($r^2 = 0,78$ e $r^2 = 0,77$, respectivamente). O NDTI apresentou

Variável	r^2	RMSE	MAE	p-value
B2	0,78	0,801	0,541	< 0,01
B3	0,81	0,744	0,472	< 0,01
B4	0,77	0,832	0,551	< 0,01
B5	0,68	0,969	0,674	< 0,01
B6	0,52	1,199	0,858	< 0,01
B7	0,50	1,217	0,867	< 0,01
B8	0,41	1,328	0,955	< 0,01
B8A	0,38	1,360	0,990	< 0,01
B11	0,23	1,515	1,168	< 0,01
B12	0,23	1,515	1,172	< 0,01
NDTI = $\frac{(\rho_{B4} - \rho_{B3})}{(\rho_{B4} + \rho_{B3})}$	0,63	1,045	0,744	< 0,01

Tabela 1: Performance da avaliação dos modelos individuais

um $r^2 = 0,63$. Supõe-se que este resultado mediano tenha sido obtido devido à baixa reflectância da água do reservatório na região do vermelho e sobressalência da reflectância na região do verde em relação ao vermelho.

Com base na análise dos dados para o modelo de turbidez e a resposta espectral da B3, a variável NDTI e as razões de banda $\frac{B3}{B2}$ e $\frac{B3-B2}{B3+B2}$ (que aqui será denominado de ITBDN – Índice de Turbidez Baixa de Diferença Normalizada) do sensor MSI/Sentinel-2 foram selecionadas de acordo com o seu comportamento em relação aos índices de turbidez amostrados. Essa seleção se deu com a finalidade de verificar o desempenho entre os dados observados e os dados preditos. Os resultados das análises são apresentados na Tabela 2.

Campanha	$NDTI = \frac{(B4-B3)}{(B4+B3)}$			$\frac{B3}{B2}$			$ITBDN = \frac{(B3-B2)}{(B3+B2)}$		
	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
Geral	0,63	1,045	-3,381	0,74	0,871	1,1395	0,77	0,833	10,7116
04/10/2019	0,85	0,307	-2,4394	0,87	0,292	0,6225	0,94	0,198	6,4083
31/05/2020	0,46	2,002	-4,642	0,58	1,766	1,5293	0,56	1,812	11,572
06/05/2021	0,91	0,427	-3,1390	0,96	0,282	1,0576	0,97	0,236	9,0926
20/06/2021	0,90	0,274	-1,887	0,92	0,238	0,7274	0,85	0,344	8,5021
24/08/2021	0,83	0,314	-1,6159	0,87	0,269	0,5964	0,94	0,176	7,0032
23/09/2021	0,88	0,881	-6,7117	0,93	0,670	1,9774	0,96	0,510	20,5391
28/10/2021	0,80	0,783	-4,4888	0,91	0,510	1,2341	0,91	0,528	10,2710

Legenda:

$r^2 > 0,90$ $r^2 0,80 - 0,89$ $r^2 0,70 - 0,79$

$r^2 0,60 - 0,69$ $r^2 0,50 - 0,59$ $r^2 < 0,50$

Tabela 2: Matriz de aplicação das melhores variáveis

Observa-se que, com as variáveis selecionadas, a campanha de 31/05/2020 apresentou o menor desempenho se comparada às demais campanhas, com r^2 variando entre 0,46 e 0,58 e RMSE entre 1,766 e 2,002. O segundo menor desempenho dos modelos foi atribuído ao conjunto de dados completo (geral) referente à todas as campanhas de campo, onde os valores de r^2 variaram entre 0,63 e 0,77 e RMSE entre 0,833 e 1,045. Para as demais campanhas, os valores de r^2 superaram 0,80, com especial atenção à campanha de 06/05/2021 que apresentou, para todos os modelos, valores de r^2 superiores à 0,91 e RMSE abaixo de 0,427.

Com relação ao desempenho individual dos modelos, de modo geral, percebe-se um melhor desempenho do ITBDN sobre o NDTI e à razão simples $\frac{B3}{B2}$. Em todos os casos, o NDTI mostrou-se inferior se comparado aos outros dois modelos. Ainda que apresentando bons resultados, a suposição de que, em função da baixa turbidez e baixa presença de material particulado em suspensão no reservatório, o NDTI de Lacaux *et al.* [9] não seja a melhor

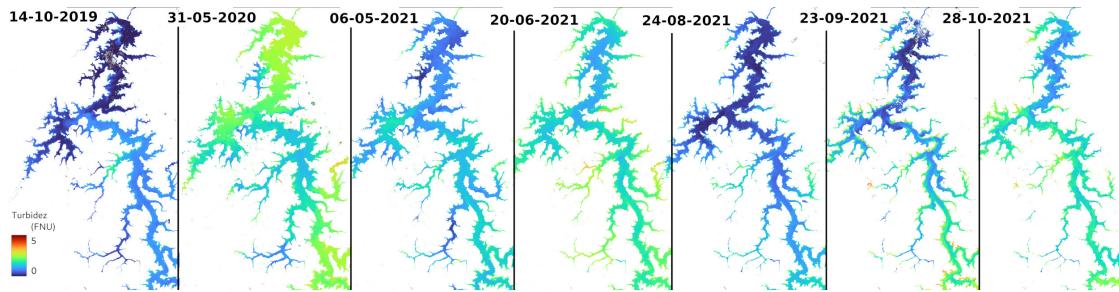


Figura 4: Série temporal de turbidez a partir do ITBDN correspondente às 7 campanhas de campo.

escolha de modelo para águas de baixa turbidez, se fortalece.

Os coeficientes β representam a mudança média na resposta para uma unidade de mudança no preditor. No modelo NDTI, verifica-se valores de β negativos indicando que, neste contexto, a medida que a turbidez aumenta, o NDTI diminui. Quando observada a relação entre as bandas B3 e B2, verifica-se valores de β positivos, que implica em uma relação positiva entre as variáveis predita e preditora. É interessante também que o coeficiente de variação do ITBDN é de 0,42 contra -0,49 para o NDTI. A Figura 4 mostra o ITBDN aplicado à represa nas sete campanhas de campo.

4. CONCLUSÕES

Este trabalho investigou a necessidade de criar um Índice de Turbidez Baixa de Diferença Normalizada (ITBDN) para águas claras a moderadamente claras. Conclui-se que:

- O Reservatório Três Marias apresenta águas claras, com baixa turbidez e material particulado em suspensão, o que implica na menor reflectância do vermelho em relação às outras bandas do visível;
- A reflectância da água do reservatório se sobressai na região espectral do verde;
- O NDTI, que utiliza a razão vermelho-verde, apresentou bom desempenho ($r^2 = 0,63$ para o conjunto total de dados), porém abaixo do desempenho apresentado pelo ITBDN, que utiliza razão verde-azul ($r^2 = 0,77$ para o conjunto total de dados);

Os resultados encontrados nesta pesquisa encorajam a continuidade de novos estudos aplicados à ambientes aquáticos diversos com as mesmas características ópticas do Reservatório Três Marias a fim de aperfeiçoar/comprovar a eficácia do modelo frente à outros corpos d'água.

5. AGRADECIMENTOS

Agradecemos ao apoio financeiro da Companhia Energética de Minas Gerais S.A. (CEMIG) através do projeto P&D GT-0607, à CAPES e ao PPG em Geografia da UFMG.

6. REFERÊNCIAS

- [1] B. Lehner, C.R. Liermann, C. Revenga, C. Vörösmarty, B. Fekete, P. Crouzet, P. Döll, M. Endejan, K. Frenken, J. Magome, et al. High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management. *Frontiers in Ecology and the Environment*, 9(9):494–502, 2011.
- [2] B.L. Kimmel and A.W. Groeger. Factors controlling primary production in lakes and reservoirs: a perspective. *Lake and reservoir management*, 1(1):277–281, 1984.
- [3] A.P.S. Silva, H.C.T. Dias, R.K.X. Bastos, and E. Silva. Qualidade da água do reservatório da Usina Hidrelétrica (UHE) de Petrópolis, Minas Gerais. *Revista Árvore*, 33(6):1063–1069, 2009.
- [4] D.L. Lima, J.S. Motta, C.A. de Souza, A.P.M. Guirra, and A.C. Paranhos Filho. Revisão bibliométrica sobre turbidez e sólidos suspensos por sensoriamento remoto. *Anuário do Instituto de Geociências*, 42(1):107–116, 2018.
- [5] C.C.F. Barbosa, E.M.L.M. Novo, and V.S. Martins. *Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações*, volume 1. Instituto Nacional de Pesquisas Espaciais, 2019.
- [6] D.F. Almeida. *Gestão ambiental dos sedimentos de corrente do Rio São Francisco na região de Três Marias/Minas Gerais*. PhD thesis, Universidade Federal de Minas Gerais, 2010.
- [7] V.P. Curtarelli. Parametrização de algoritmos semi-analíticos para estimativa do coeficiente de atenuação difusa espectral (Kd) do Reservatório de Três Marias por sensoriamento remoto. Master's thesis, Instituto Nacional de Pesquisas Espaciais, 2020.
- [8] R.M.P. Ferreira. Caracterização da ótica e do carbono orgânico dissolvido no Reservatório de Três Marias/MG. Master's thesis, Instituto Nacional de Pesquisas Espaciais, 2014.
- [9] J.P. Lacaux, Y.M. Tourre, C. Vignolles, J.A. Ndione, and M. Lafaye. Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley fever epidemics in Senegal. *Remote Sensing of Environment*, 106(1):66–74, 2007.
- [10] V. Lonjou, C. Desjardins, O. Hagolle, B. Petrucci, T. Tremas, M. Dejus, A. Makarau, and S. Auer. MACCS-ATCOR joint algorithm (MAJA). In *Remote Sensing of Clouds and the Atmosphere XXI*, volume 10001, pages 1–13. International Society for Optics and Photonics, 2016.
- [11] S.K. McFeeters. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7):1425–1432, 1996.
- [12] G.H.A. Pereira, M. Lohmann, and R.F. Maganhotto. Proposta e avaliação de índices para delimitar e mapear corpos d'água utilizando imagens do satélite Landsat-8. *Revista Brasileira de Geografia Física*, 9(06):1956–1968, 2016.
- [13] E.M.L.M. Novo, C.C. Barbosa, and F.L. Lobo. Comportamento espectral dos ambientes aquáticos. In P.R. Meneses, T. Almeida, and G.M.M. Baptista, editors, *Reflectância dos materiais terrestres: análise e interpretação*, chapter 7, pages 225–245. Oficina de Textos, São Paulo, 2009.

ANEXO G – Artigo: Determining the most suitable Sentinel-2 indices for turbidity and chlorophyll-a concentration for an oligotrophic to mesotrophic reservoir in Brazil

PIZANI, F.M.C.; AMORIM, C.C.; MAILLARD, P.. Determining the most suitable Sentinel-2 indices for turbidity and chlorophyll-a concentration for an oligotrophic to mesotrophic reservoir in Brazil. Int. J. Hydrology Science and Technology, 2023. Submitted December 2022, Under revision.

Determining the most suitable Sentinel-2 indices for turbidity and chlorophyll-a concentration for an oligotrophic to mesotrophic reservoir in Brazil

Abstract: Water quality is a major issue for agencies responsible for the management and maintenance of reservoirs. In this article, Sentinel-2 (S-2) data is tested to produce reliable estimates of turbidity and chlorophyll-a concentrations in an oligotrophic to mesotrophic reservoir in Brazil. The spectral bands were all tested individually and jointly to determine the best and most stable features. Many indices are also tested. In situ data was acquired over a period of three years with synchronous S-2 data. The models were evaluated on their robustness and stability using a bundle of in situ dataset (all field campaigns). The results show that no model can be directly applied to other reservoirs or different dates without calibration. Conversely, calibrating the S-2 indices with two in situ measurements greatly reduces the errors. Average root mean square errors of 0.518 FNU and 1.1 µg/l were obtained for turbidity and chlorophyll-a concentrations respectively.

Keywords: chlorophyll-a, turbidity, empirical models, Sentinel-2, reservoir

1 Introduction

1.1 Water Quality of Reservoirs

It is estimated that there are approximately 16.7 million reservoirs larger than 0.01 ha in the world representing 8070 km³ and a total area in excess of 300 000 km² (Lehner et al. 2011). Reservoirs are considered to be between lentic and lotic environments since many were built by damming a river or stream (Ackermann et al. 1973). Reservoirs are generally considered to contain fresh water but can be saline (e.g. coastal reservoirs) or brackish in rare cases (Lake Texoma, between the states of Texas and Oklahoma). Reservoirs are also important reserves of energy and drinkable water as well as leisure areas. As such, those reservoirs used especially for water supply need to maintain sufficient water quality standards to prevent health issues in the populations that benefit from it. It is then essential for agencies responsible for managing these reservoirs to monitor their quality. Traditionally this monitoring is being done through in situ water sampling and laboratory analysis or by using water quality measurement instruments (e.g. turbidity-meter, ph-meter, etc.) or multi-parameter sonde capable of instantly measuring various parameters at once. The costs of these campaigns is, however, generally high in terms of logistics, equipment and personnel. Additionally, it rarely manages to be spatially representative and often considered too infrequent to capture the true dynamics of the water quality.

Since its beginning as a civilian scientific technique in the 70's, remote sensing has been used to estimate a few water quality parameters of superficial waters both inland and in oceans. For inland waters, the Landsat program (1972-) is perhaps the most significant advancement in terms of water monitoring from space. The first three Landsat satellites carried the MSS instrument with coarser spatial resolution (68 m X 83 m, often resampled to 50 m, or 60 m) and all subsequent Landsat missions used multispectral sensors with a

2 *Removed for double-blind peer review*

finer 30 m spatial resolution (TM, ETM+ and OLI). While the MSS instrument provided good estimates of surface suspended sediments, it did not produce satisfactory models for chlorophyll-a (Ritchie et al. 1990). Conversely, many studies have had better success with Landsat's TM, ETM+ and OLI to estimate Secchi disk depth (SDD) (Mancino et al. 2009, Giardino et al. 2014, Xu et al. 2018), total suspended matter (TSM) (Jiang et al. 2010, Tu et al. 2018), Chlorophyll-a (chl-a) (Huo et al. 2014, Bonansea et al. 2018, Torbick et al. 2018), coloured dissolved organic matter (CDOM) (Brezonik et al. 2005, Chen et al. 2017) turbidity (Alparslan et al. 2010, Quang et al. 2017a, Silva et al. 2020) and other parameters less studied.

1.2 Turbidity

Turbidity is the result of particles of both organic and non organic origin in the water. Turbidity can be caused by the presence of matter of phytoplanktonic origin and an increase in turbidity can be associated to the number of plant pigments in the water column (Sabat-Tomala et al. 2018). Materials of mineral origin from soil erosion also contribute to water turbidity (Menken et al. 2006). Notwithstanding the specific characteristics of each indicator, TSM and turbidity can be considered directly correlated parameters (Odermatt et al. 2008). The nature and concentration of these particles alter the spectral characteristic of the water. Hence, there is no 'typical' colour of turbid water.

Although considered an effective method, the use of remote sensing for estimating WQ parameters in complex continental aquatic environments with high levels of turbidity is still a challenge (Robert et al. 2017). The use of the red spectral range in single band algorithms can produce extremely consistent and robust models for turbidity in highly turbid water using high-resolution sensors, such as Landsat-OLI (Quang et al. 2017a). However, ratio models of two or more spectral bands are more commonly used. The two-band models using the 412 nm and 560 nm wavelengths showed good estimates with low spatial resolution images from MERIS (Potes et al. 2012), as well as using high-resolution images from the MSI (Elhag et al. 2019) and REIS (Avdan et al. 2019) sensors combining the green and red bands.

Even though many authors consider that in turbid water the reflectance in red increases with respect to the green reflectance (Lacaux et al. 2007), it is not always the case. It might be truer during the wet season when important loads of sediments are washed in the waters through runoff; in the dry season, other processes may be responsible (i.e. irrigation, point pollution).

1.3 Chlorophyll-a

Phytoplankton communities represent one of the WQ parameters that can be detected and monitored by remote sensors. In fact, it is by far the most 'popular' WQ parameter to be considered amongst the specialised remote sensing publications (probably also because it represents an increased scientific challenge). The analysis of the trophic state and WQ of a lake or reservoir is related, among other factors, to the abundance of phytoplankton (Bresciani et al. 2020). An increase in the concentration of these species is a major cause of water contamination (Peppa et al. 2020). High nutrient loads (nitrogen and phosphorus) accelerate the growth and biomass production of algae (Pyo et al. 2018) and can be associated with phytoplankton blooms (Wilkie et al. 2019). There is real concern about cyanotoxins blooming in water bodies as these toxins pose an effective threat to public

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 3

health. Detection via remote sensing of these algal blooms in continental waters, which could contain harmful cyanobacteria, has been mostly based on the estimation of chlorophyll-a (chl-a) and Phycocyanin (PC)(Ogashawara 2019).

Usually, cyanobacterial blooms appear in the morning due to the respiratory process that occurs during the absence of light, which explains the disappearance of these blooms in the afternoon and reappearance in the morning (Bresciani et al. 2018). Seasonal factors such as temperature rise and wind dynamics also influence the distribution, abundance and diversity of phytoplankton species (Bresciani et al. 2020). The time of emergence of blooms (morning) favours the use of optical remote sensing to estimate this parameter through its relationship with chlorophyll. There is a difference in the absorption and reflection of light between water with predominant concentration of phytoplankton (Case 1) and more complex water, with high levels of turbidity, CDOM and TSM (Case 2) (Malahela et al. 2018). Several authors indicate the appropriateness of using algorithms like the blue/green band ratio for Case 1 (Ansper & Alikas 2019, Zeng & Binding 2019) while the use of bands in the NIR and red regions are more applicable to the waters of Case 2, since the interference of the non-algal particle response and CDOM are reduced in these regions (Cheng et al. 2013). In addition to the blue/green and NIR/red ratios to estimate the concentration of chl-a, studies often adopt a third algorithm based on spectral curvature that uses a three-band ratio: Maximum Chlorophyll Index (MCI, which uses a central band at 706 nm) is an example of this kind of algorithm (Flores-Anderson et al. 2020).

1.4 Sentinel-2 for Water Quality

The Copernicus / European Space Agency - ESA Sentinel-2 (S-2) mission is a dual satellite constellation: S-2A was launched in June 2015, S-2B in March 2017. Together they can produce an image of virtually any place on Earth every 5 days (less in mid latitudes). The S-2 satellites carry on-board the Multi-Spectral Instrument (MSI) with 13 spectral bands as described in Table 1. Four of these bands (2, 3, 4, 8) have a spacial resolution of 10 m (three visible bands and one near infrared - NIR), six (5, 6, 7, 8A, 11, 12) have a 20 m resolution (one NIR, three red edge - RE and two short wave infrared - SWIR) and three bands (1, 9, 10) have a 60 m resolution (one for coastal/aerosols estimation in the blue, one for water vapour in the NIR and one cirrus detection in the SWIR). By comparing the bands with Landsat-8 -9's OLI sensor (Table 1), it is mostly the addition of the three RE bands that spectrally distinguishes the two instruments.

Apart for the finer spatial resolution (10–20 m vs 30 m), the S-2 bands also generally have a finer spectral resolution in the green, red and NIR. These three advantages (spatial, spectral and shorter revisit time) make S-2 a good candidate for monitoring the quality of inland waters such as lakes and reservoirs. The Landsat-8 and -9 have received much attention for estimating a series of optically active water quality parameters and are very valuable and together the two missions can supply an image every three days at the equator on average (31 non-repeating dates images in 100 days).

S-2 images have been tested and used in a number of water quality monitoring studies with very variable results. It appears the particular context in which it was used has had a strong effect on the quality of the results. Generally speaking (but not systematically), the best results are often obtained when the intervals of the parameter being estimated is larger or when the quality of the water is strongly affected (i.e. very turbid and/or eutrophic). Still, S-2 has proven to be quite reliable for estimating the more optically active parameters such as turbidity, chlorophyll-a (Chl-a), coloured dissolved organic matter (CDOM), total

4 *Removed for double-blind peer review*

suspended matter (TSM) and Secchi disk depth (SDD). The following points give a general overview of some of the results obtained in a number of situations.

- TSM: Authors have found that the best results were obtained with red edge band 705 nm for clear, turbid and brown waters but with a very different weight (beta weight) for each (Soomets et al. 2020). Others suggested to have achieved best result with blue-green ratio for clear and moderate water and a complex model involving sum of Red Edge (740 nm) and NIR (865 nm) band for turbid to brown waters (Uudeberg et al. 2020).
- CDOM: The red-blue and green-blue ratios for moderate to brown waters (linear and exponential models) produced better results in (Uudeberg et al. 2020) while another study obtained best results with red-green ratio ($r^2 \approx 0.4$ for brown to moderate waters; $r^2 \approx 0.74$ for clear) (Uudeberg et al. 2020).
- Chl-a: A study (Watanabe et al. 2018) found that S-2 was better than L-8 for estimating chl-a; another (Ha et al. 2017) found S-2 B3/B4 ratio ($r^2 = .65$) to be better than B5/B4 ($r^2 = .29$) for case 2 (complex) waters with chl-a concentrations of $1.6 - 6 \mu\text{g/l}$; in lakes with high chl-a content the 3-bands ratios (665,705,740) was better while the ratios 705-665/705+665 and 705/665 were better for waters with high TSM ($19 \mu\text{g/l}$) if chl-a is lower than $11 \mu\text{g/l}$ (Ansper & Alikas 2019); By classifying the water in five different optical water types (OWT: clear, moderate, turbid, very turbid, brown) it was determined that different ratios were better for different OWT (Ansper & Alikas 2019) and that r^2 generally increases with turbidity (0.67 for clear, 0.90 for brown). The MCI (maximum chl-a index) (Binding et al. 2013) that uses B4,B5,B6 has been producing good results for eutrophic waters but not for oligotrophic or mesotrophic waters and so was MPH (maximum peak-height) (Peppa et al. 2020); MPH (maximum peak-height) (Matthews et al. 2012) that uses B4, B5 and B8A works better for mesotrophic to eutrophic/hypertrophic waters.
- SDD: It was found in a study (Rodrigues et al. 2017) that L-8 was slightly superior to S-2 (but simulated bands were used); (Soomets et al. 2020) got best results with a light attenuation coefficient at 490 nm (K_d490) calculated using reflectances at 490, 560, and 705 nm; (Uudeberg et al. 2020) obtained best results with blue-red ratio.
- Turdidity: Turbidity is highly related to TSM; methods with Landsat and S-2 usually give good results with the visible bands (single or ratio) (Quang et al. 2017b, Ouma et al. 2020) and sometimes using the NIR band in very turbid waters; similar results are obtained with L-8 and S-2 using only visible bands in different model configurations (Ouma et al. 2020); a turbidity index (NDTI: B3-B2/B3+B2) was proposed by (Lacaux et al. 2007) which can produce good results in very turbid waters.

Comparing the two missions in a previous study, we found that S-2 was generally superior and decided to concentrate our efforts on its potential (Removed for double-blind peer review)The main objective of this study consists in developing a method to monitor turbidity and chlorophyll-a concentrations in 'case 2' waters of relatively good quality using Sentinel-2 data. It also aims at developing software tools to facilitate this monitoring in an operational approach.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 5

Table 1 A spectral band comparison between Landsat-8 -9 OLI sensor and Sentinel-2A -2B MSI sensor. *Slight differences exist between S-2A and S-2B but were not considered here and average values were used instead. **Note that the min-max values of the MSI sensor were calculated based on the band width.

Band name	Landsat-8 -9 OLI bands			Sentinel-2A -2B MSI* bands				
	n°	center	min-max	width	n°	center	min-max**	width
Coastal	1	0.443	0.435-0.451	0.016	1	0.443	0.433-0.453	0.020
Blue	2	0.482	0.452-0.512	0.060	2	0.493	0.461-0.525	0.065
Green	3	0.561	0.533-0.590	0.057	3	0.560	0.542-0.578	0.035
Red	4	0.655	0.636-0.673	0.037	4	0.665	0.650-0.680	0.030
Red Edge					5	0.704	0.696-0.712	0.015
Red Edge					6	0.740	0.733-0.747	0.014
Red Edge					7	0.781	0.771-0.791	0.019
NIR					8	0.833	0.781-0.985	0.105
NIR	5	0.865	0.851-0.879	0.028	8A	0.864	0.853-0.875	0.021
Vapor					9	0.944	0.934-0.954	0.020
Cirrus	9	1.373	1.363-1.384	0.020	10	1.375	1.360-1.390	0.029
SWIR	6	1.609	1.566-1.651	0.085	11	1.612	1.539-1.681	0.094
SWIR	7	2.201	2.107-2.294	0.187	12	2.194	2.072-2.312	0.184

2 Materials and Methods

As reviewed in the introduction, most water quality studies based on remote sensing that seek to characterise WQ in inland water environments concentrate on areas with a relatively high level of WQ problems, such as eutrophic ($\text{chl-a} > 10 \mu\text{gl}^{-1}$) and highly turbid waters ($> 30 \text{ NTU}$). Conversely, monitoring these environments for which thresholds in WQ parameters are comparatively low represents a different challenge. This is the case of the *Três Marias* Reservoir for which the managing agency (CEMIG) is required to regularly monitor its WQ weather or not there is a threat to it. For these agencies, the ability to demonstrate the effectiveness of remote sensing represents a definite advancement and a significant cost reduction.

To contemplate such an objective, we approached the problem from a fresh viewpoint in the sense that we did not make assumptions about whether measuring low threshold WQ parameters would be possible with an appropriate accuracy. This attitude made us define an experimental design that would minimise over-fitting and maximise exportability in environments with good WQ. The following precautions were progressively determined during the course of our four year project. These topics are further discussed below.

- Perform several in situ surveys;
- Cover most of the reservoir;
- Ensure that all surveys are coincident with satellite passages;
- Use only reliable calibrated measurements (multi parameter sonde);
- Validate some sonde measurements with laboratory measurements;
- Build both individual per-survey empirical models and cross-survey models;

6 *Removed for double-blind peer review*

- Determine the strength of all sensor bands as well as derivative variables (e.g. band ratios);
- Code application tools to facilitate modelling, testing and validating;
- Propose a robust cross-survey model;
- Propose an operational approach to water quality monitoring
- Test models in another reservoir environment.

2.1 *Field work*

Planning field work carried a special importance and was a critical part of the project. Due to the COVID19 pandemic many field operations had to be cancelled (mostly during 2020) which resulted in a significant reduction of field data. It was decided that all field campaign planned to be used for building models based on remote sensing data (some field work was also dedicated to acquire subsurface WQ data not directly related to the remote sensing part of the project) would have to be carried out the same day and within four hours of the satellite passage. The instrumentation consisted in a multi-parameter sonde (YSI EXO2 Multiparameter Water Quality Sonde) equipped with the following sensors: chlorophyll-a, conductivity, dissolved organic matter (fluorescence), biological demand of oxygen, total dissolved solids, pH, turbidity and temperature. The sonde also records depth and geographic coordinates through its internal GNSS. A Secchi disk was also used to measure water transparency. Water samples were also collected for a small number of sampling sites and for most field campaigns. The laboratory processing of water samples requires a special logistic care especially for chlorophyll that is known to degrade rapidly. Because chlorophyll levels are known to be rather low in *Très Marias*, a large quantity of water had to be collected (≈ 5 litres) for each sampling site and this also involved carrying large quantities of ice to preserve the samples.

As mentioned in the introduction, for operational reasons, we concentrated our efforts on monitoring turbidity and chlorophyll concentrations. Other optically active parameters such as TSM and CDOM had low concentrations that were not always measurable by the multiparameter sonde and the amounts that would need to be collected for laboratory analysis were too large for our logistics.

2.2 *Image data acquisition*

It was initially decided to use both Sentinel-2 and Landsat-8 data (Landsat-9 was only made available in November 2021) and especially when S-2 and L-8 were coincident (once every 80 days). Eventually we decided to concentrate our efforts on S-2 for a number of reasons. Firstly, combining S-2A and 2B permitted a revisit time of 5 days against 16 for L-8 which facilitated greatly the planning of field surveys and their postponing when weather and cloud cover conditions were inappropriate. Postponing once or twice for a 5 day revisit time was much less impacting than 16 or 32 days for L-8. Secondly, we found early on that S-2 tended to yield better results than L-8, partly because of the finer spatial resolution (10–20 m vs 30 m), but mostly because of the finer spectral resolution of S-2 and the inclusion of RedEdge bands unavailable with L-8 (Watanabe et al. 2018) The RedEdge bands appear to be beneficial for estimating chlorophyll-a concentrations.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 7

All the S-2 images were obtained from the CNES (*Centre National d'Etudes Spatiales*) PEPS platform (*Plateforme d'Exploitation de Produits Sentinel*) to which the MAJA (MACCS ATCOR Joint Algorithm) atmospheric correction was applied. Luckily, practically 100% of the reservoir was covered by a single S-2 tile (T23KMF) which simplified image acquisition and processing.

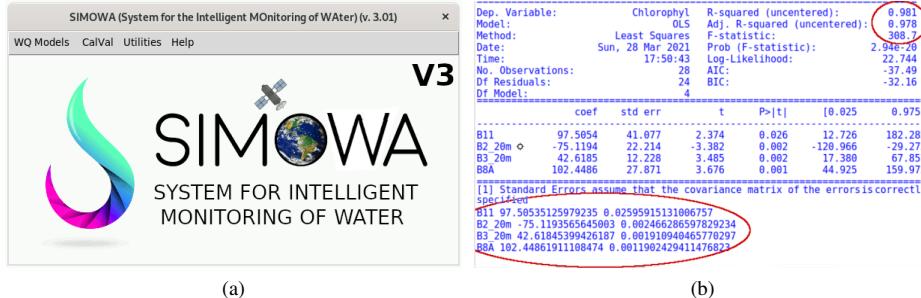
2.3 Multiple regression models

Among empirical approaches to WQ models using remote sensing, correlation, simple and multiple regression are by far the most used inferential techniques. If, in one hand they tend to produce a simple and efficient way to infer some WQ parameters, on the other hand they are also difficult to export in other sites or even other dates/seasons (Matthews 2011). The use of satellite calibrated spectral data transformed in 'bottom-of-atmosphere' (atmospheric correction) reflectance has improved significantly our ability to build more robust inferential models. Still, other factors hinder the application of WQ models to other environments or even other periods of the same region. Even with advanced atmospheric correction algorithms such as the algorithms SEN2COR and MAJA (Sentinel-2) or LEDAPS and LaSRC (Landsat), models are highly sensitive to small errors these estimates produce (Matthews 2011). Other problems include non-linearity that prevent models to work well outside of the range for which they were created and the co-variation of two or more WQ parameters that produce non-unique solutions like when turbidity and chl-a vary independently from one another but produce a single optical response. Such WQ parameters are also the simplification of a more complex situation. For instance equal concentration of suspended sediments of different origin (e.g. clay vs silt) will produce a different spectral response.

Considering these difficulties, we designed our approach in order to minimise their effect by 1) simplifying the models while maintaining a high efficiency (coefficient of determination), 2) evaluating both native spectral bands and derived features (e.g. ratios), 3) using robust feature selection algorithms, 4) comparing models built from different survey measurements, 5) building generic models to fit all in situ data sets and 6) performing cross-validation with another reservoir.

Simplifying the models meant for us the use of as little features as possible while maintaining a high coefficient of determination, but also meant trying to keep the same selected features throughout all the surveys. In other words, giving priority to features (spectral bands and ratios) that are common to the largest number of individual models produced from each in situ field campaign data. This required the evaluation of all features using techniques such as their significance (P value) and feature selection and ranking using 'a knock-out algorithm'. The knock-out algorithm is a sub-optimal feature selection approach developed by Sambur (Sambur 1975). The 'knock-out' algorithm is iterative; for N features, it first performs all the possible regressions using $N-1$ features then rejects the feature that was not included in the best result (highest r^2) obtained. The algorithm then proceeds with $N-2$, $N-3\dots N-(N-1)$ so that all the features are given a performance rank. All models were also compared in terms of performance by applying them to S-2 images of other dates for which in situ data was available, and then evaluated through measurements of error.

A 'generic' model was built in an attempt to predict the two surface WQ parameters in any image of the *Três Marias* Reservoir and possibly other reservoirs with similar characteristics. The generic model was created using all in situ survey points regardless of



(a)

(b)

Figure 1: Graphical interface of the SIMOWA tool (a) and representation of the statistical results (b) with the r^2 score and β weights highlighted in red.

their acquisition date by creating a bundle dataset that included reflectance values extracted from their respective image. The generic model was evaluated through its ability to predict the two WQ parameters with acceptable precision.

2.4 Validation

Validation was performed by evaluating both performance (r^2) and estimates of the following error metrics: Mean Error (ME), Mean Absolute Error (MAE) and Root Mean Square Error (RMSE). With data from eight surveys¹, each corresponding to a synchronised S-2 image acquisition, validation was performed for each survey date as well as for the bundle dataset containing all the survey data. In addition, a survey from another reservoir (*Várzea das Flores*) was used to validate our approach.

2.5 SIMOWA, a remote sensing tool for the operational monitoring of water

The SIMOWA program was developed in Python 3 as a work tool to generate and test multiple regression models combining in situ and satellite image data. Initially SIMOWA accepts a *shapefile* with WQ data (being the attributes of the geo-coded points) and the associated spectral data (retrieved by Google Earth Engine - GEE(Gorelick et al. 2017) for instance) or even a level 2 satellite image ('bottom-of-atmosphere' atmospheric correction) from Sentinel-2 or Landsat-8 to produce regression models. The program allows you to manually select the bands or let a stepwise process eliminate the low-impact spectral bands in the model, based on the significance (P) of the spectral variable. SIMOWA has its own graphical interface (Figure 1) consisting of a main window and some dependent (child) windows. SIMOWA uses the "Shapefile", "Statsmodel" and "Pandas" packages to read the data, calculate and store the regression models. The results are presented in the form of a model file (weights) and a statistical report, both stored. A module allows you to apply any model to an image as long as it is of the same type (same bands) and has the same correction level (L2). Once applied, the result is stored in a GeoTiff file. In addition SIMOWA can be used to produce simple ratios or normalised difference indices. Its calibration module lets the user linearly transform a feature (band or index) using two in situ points and generates a short validation report.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 9**Table 2** Field surveys in *Três Marias* along with the parameters collected/measured between 2019 and 2021

Data	Nº of points	Parameters	Method
01 / Jul / 2019*	7	Chl-a ($\mu\text{g/L}$)	Spectrophotometer
		Transparency (cm)	Secchi disk
04 / Oct / 2019	13	Chl-a ($\mu\text{g/L}$)	Laboratory
		Chl-b ($\mu\text{g/L}$)	Laboratory
		Chl-c ($\mu\text{g/L}$)	Laboratory
		Turbidez (FNU)	Turbidimeter Lab1000
		Transparency (cm)	Secchi disk
31 / May / 2020	13	Temperature (T°)	Oxymeter HACH (HQ430D)
		Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk
06 / May / 2021	30	Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk
20 / Jun / 2021	22	Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk
24 / Aug / 2021	29	Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk
23 / Sep / 2021	26	Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk
28 / Oct / 2021	35	Chl-a ($\mu\text{g/L}$)	Sonde EXO2 (YSI)
		Turbidity (FNU)	Sonde EXO2 (YSI)
		Transparency (cm)	Secchi disk

*Source: Curtarelli et al., 2020

3 Results

3.1 Field work and data

All field surveys were carried out within four hours of the satellite passage of either Sentinel-2 A or B. In all, eight such campaigns were carried out, seven of which by the authors. The remaining field work data were kindly provided by INPE (Brazilian National Institute of Space Research) and are reported in (Curtarelli et al. 2020). A total of 175 measurements point of numerous water quality parameters, both optically active and non-optically active were obtained. The dates, parameters and instruments are specified in Table 2. Other parameters may have been collected or measured but were omitted here for not being directly related to the present article. Figure 2 shows the spatial distribution of the survey points in the reservoir. All surveys were done on clear days and the corresponding images all had less than 10% of clouds, the majority of which away from the reservoir (Figure 4).

The levels of turbidity (Figure 3a) and chlorophyll-a (Figure 3b) are shown in the boxplots of Figure 3. These levels are generally considered quite low and sometimes barely

10 *Removed for double-blind peer review*

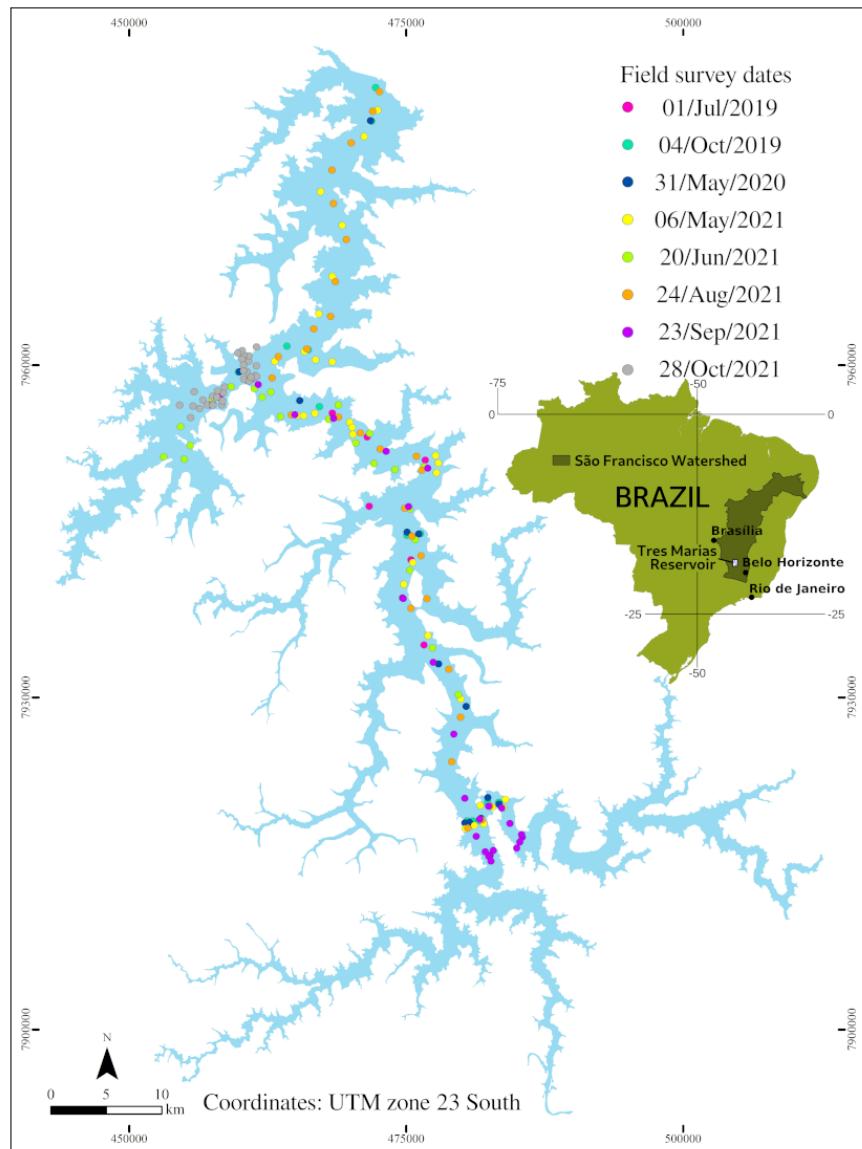


Figure 2: Distribution of survey points in all field campaigns.

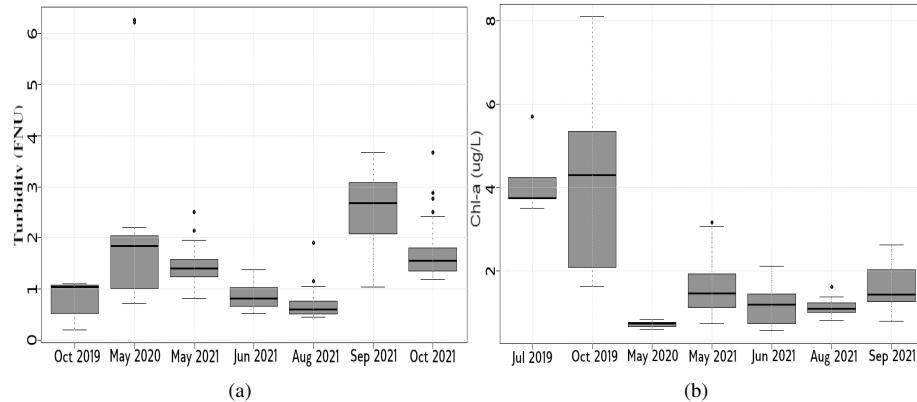


Figure 3: Boxplot graphs showing the dynamic range of turbidity (a) and chlorophyll-a concentrations (b) for the all survey dates.

measurable through our YSI EXO2 sonde. Although these waters are considered of relatively good quality for a reservoir, they still need to be monitored. Considering turbidity below 5 FNU (except one measurement) and chl-a concentrations between 0 and 8 $\mu\text{g/l}$, the waters of *Três Marias* are considered oligotrophic to mesotrophic at most (Canfield Jr et al. 1983, Wetzel 2001). For instance these chl-a concentrations can represent a limitation since most studies using remote sensing products to estimate chl-a report root mean square errors in excess of 5 $\mu\text{g/l}$ (Removed for double-blind peer review)Conversely, many studies have been able to measure turbidity levels in similar ranges.

3.2 Sentinel-2 data

Figure 4 shows the near infrared band (8A) of all eight images matching our survey dates. It can be observed that the water surface of the reservoir is almost completely free of clouds in all cases. Figure 4 also shows clearly that the water level of the reservoir varied significantly between the different surveys. This is confirmed by the water level graph shown in Figure 5 which varied between 560.22 m (lowest) and 571.83 m (highest). Each graph shows the spectral response of all survey points. Although not all months are being represented, it appears that the months of September and October show the highest variation compared with the May-August months (usually the dryest).

All images were obtained from the PEPS platform of the french CNES (*Centre National d'Etudes Spatiales*) and were transformed in flat surface reflectance (FSR) using the MAJA processing algorithm (MACCS-ATCOR Joint Algorithm (Hagolle et al. 2021)) also made available on the PEPS platform.

3.2.1 Spectral behaviour of the waters of *Três Marias Reservoir*

The spectral behaviour of the water in the *Três Marias* Reservoir for each sampling points is illustrated in Figure 6. Each line represents the behaviour of a single sampling point after atmospheric correction of the image. On all campaigns, a reflectance peak is observed in the green region (≈ 560 nm). The presence of suspended sediments normally contributes to the increase of reflectance at longer wavelengths (mostly red). In the *Três Marias* Reservoir,

12 *Removed for double-blind peer review*

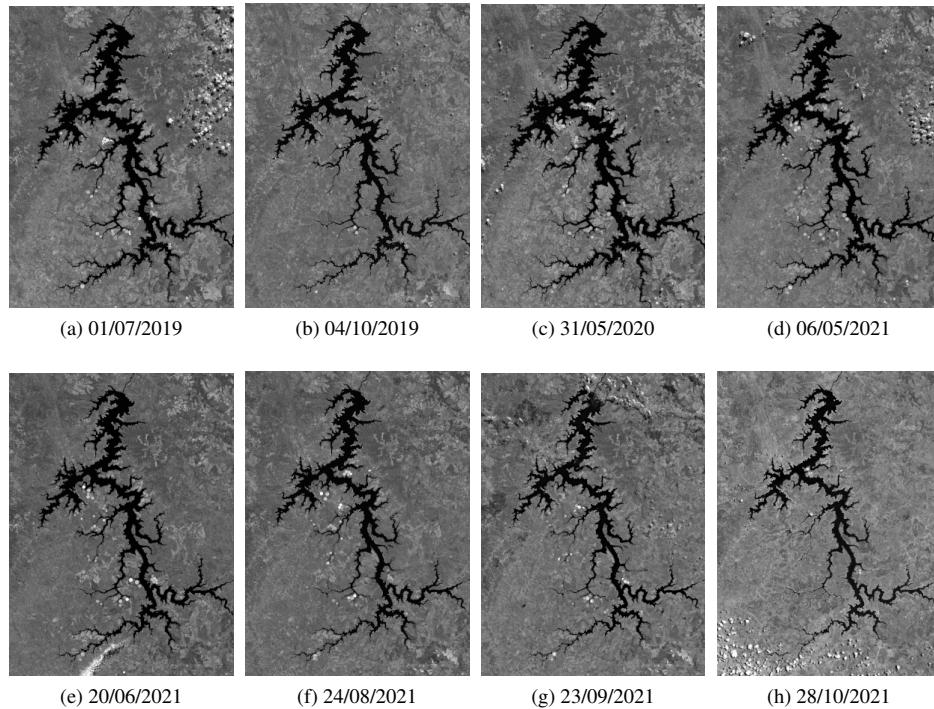


Figure 4: Subscenes of the eight Sentinel-2 images (near infrared band 8A) showing the near absence of clouds. Note how the last image shows the reservoir at its lowest level.

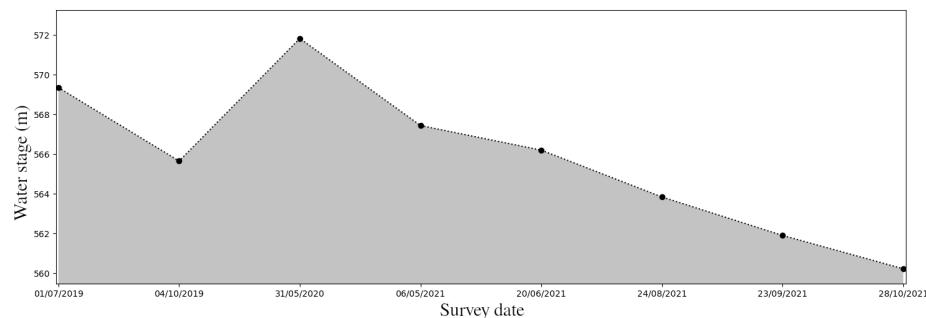


Figure 5: Graph showing the water level during each of the eight field surveys in *Três Marias*.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 13

this was not observed: in general, there is a decrease in intensity as the wavelength increases beyond the green. In the several attempts to record the total suspended solids using the EXO2 sonde, no measurable values were recorded above the detection threshold. A slight variation in the intensity can be observed in the *red-edge* (≈ 783 nm) and NIR (≈ 865 nm) portion of the spectrum during the May, August and September campaigns of 2021.

There is a greater range of variation in reflectance values of the campaigns carried out in October 2019 and 2021. The point with the highest spectral reflectance among all campaigns was sampled in October 2021, reaching $\rho \approx 0.08$. The smallest amplitude was observed in July 2019, carried out by INPE (Curtarelli 2020). On this occasion, the intensity variation of the values was between 0 and ≈ 0.03 , with the highest value being located near Porto Novo, in Morada Nova de Minas. It is important to note that the sampling points in this campaign are concentrated in the central part of the reservoir (Figure 2).

Most sampling points with the highest spectral reflectance are located in the confluence region between the *Paraopeba* and *São Francisco* rivers with the exception of the May 2019 campaign where the highest reflectance in the green wavelength ($\rho \approx 0.075$) was recorded near the reservoir dam.

Clear water shows very low spectral reflectance mostly due to the scattering of light in the 400–500 nm region (apparent optical properties), with values around $\rho < 2\%$ (Jensen 2014). It is assumed that the reflectance of light in the infrared region approaches zero in slightly turbid waters (Barbosa et al. 2019). The sampling points at different dates and in different regions of the reservoir did not exceed the value of $\rho \approx 8\%$ of spectral reflectance, which reinforces the characteristic of a reservoir as an environment of clear to moderately clear water.

3.3 Turbidity results

Table 3 shows the results of simple linear regression between the turbidity measurements (all seven campaign together) and the reflectance data from each S-2 band (less the three 60 m bands). It is striking that all visual bands produce good results with coefficients of determination (r^2) above 0.8. Even the three red edge bands yield r^2 between 0.67 and 0.75 while the NIR and SWIR bands have r^2 between 0.51 and 0.66. These are interesting results showing that simple models can produce good estimates across time within the confines of the reservoir. We also tested various more commonly found turbidity indices from different authors to determine which can be used in our particular context (Table 4). Two indices ($Turb_1$ and $Turb_3$) performed poorly with r^2 below 0.3. $Turb_2$, $Turb_4$ and $Turb_5$ had average performances (r^2 between 0.57 and 0.66) and $Turb_6$ had the best performance with $r^2=0.8$. It turns out that, in the low turbidity conditions of our reservoir, single bands perform better than the turbidity indices.

Noticing the very good performance of the blue (B2) and green band (B3) of Sentinel-2, we tested the use of a ratio based on these two bands to see how it would compare to the other indices. We called this index a Normalised Low Turbidity Difference Index (*NLTDI*) for which the results are shown on the last line of Table 4. The *NLTDI* turns out to have a very similar performance than the $Turb_6$ index and these two indices have the best overall performance among the indices.

Based on these results, we tested all combinations of S-2 bands in a multiple regression setting and came out with the best combination using only B2 and B3 for the overall dataset (all *in situ* campaigns together) as well as for the individual campaigns. This same approach was used for testing the different turbidity indices that performed well on the overall dataset

14 *Removed for double-blind peer review*

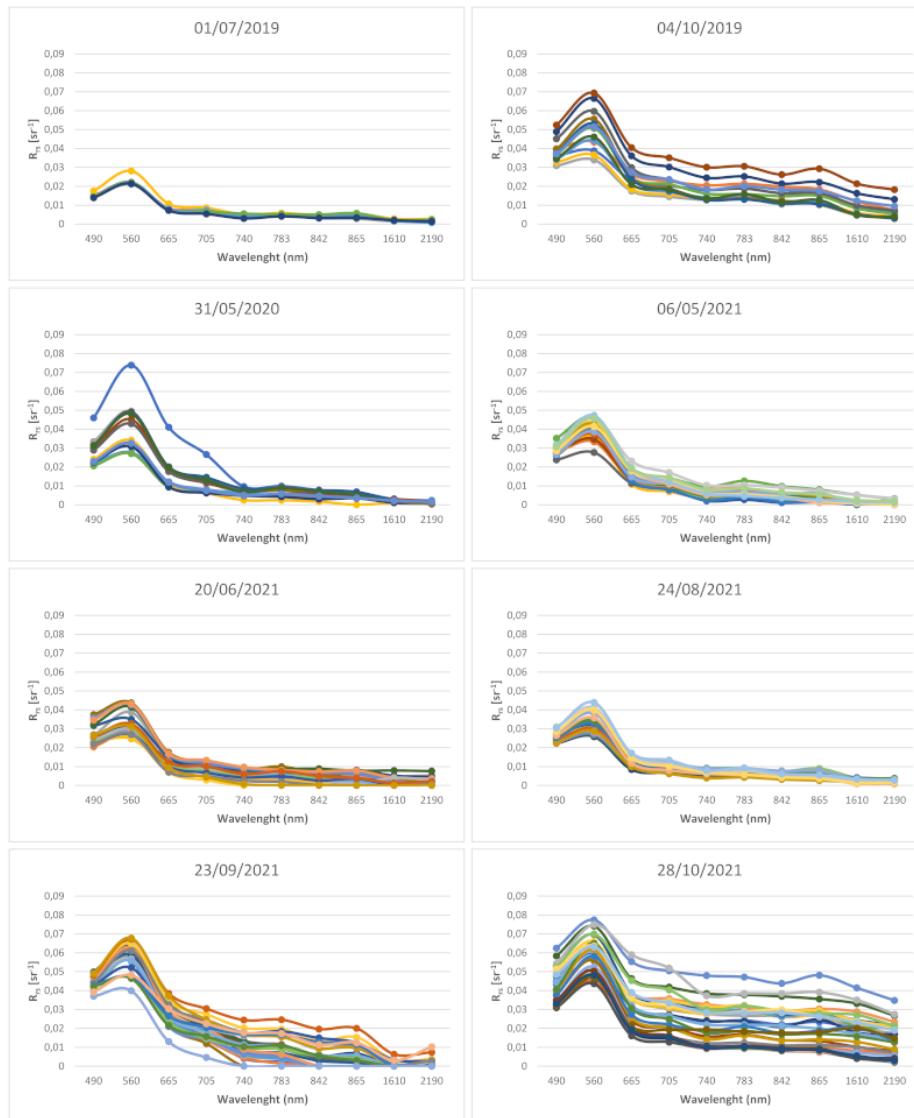


Figure 6: Spectral behaviour of all survey points per survey date showing the dynamics of the spectral variations observed for each survey date.

Table 3 Performance of the individual spectral bands of S-2 for estimating turbidity.

ID	Band	r^2	RMSE	MAE	p-value
B2	B2	0.84	0.669	0.445	< 0.01
B3	B3	0.88	0.578	0.387	< 0.01
B4	B4	0.81	0.711	0.510	< 0.01
B5	B5	0.75	0.824	0.603	< 0.01
B6	B6	0.67	0.961	0.718	< 0.01
B7	B7	0.67	0.949	0.707	< 0.01
B8	B8	0.66	0.974	0.730	< 0.01
B8A	B8A	0.64	1.000	0.759	< 0.01
B11	B11	0.55	1.114	1.128	< 0.01
B12	B12	0.51	1.167	0.907	< 0.01

Table 4 Performance of different 'Indices' for estimating turbidity

ID	Index	r^2	RMSE	MAE	p-value
Turb ₁	1048.8 * [(B2 + B8) * B8] (Wang et al. 2021)	0.28	1.412	1.128	< 0.01
Turb ₂	0.419 + (-94.129 * B2) + (56.261 * B3) + (135.372 * B4) + (-110.431 * B8) (Kapalanga et al. 2021)	0.65	0.535	0.264	< 0.01
Turb ₃	5.76 + 737.3 * (B5-B11) - 2.277 * (B2/B12) + 9.327e-04 * (B2/B12) (Torres-Bejarano et al. 2021)	0.04	1.633	1.371	< 0.01
Turb ₄	0.4121 * [(B8*B4)/B3] ² - 31.74 * [(B8*B4)/B3] + 612.17 (Abdelmalik 2018)	0.57	1.092	0.862	< 0.01
Turb ₅	NDTI = (B4-B3)/(B4+B3) (Lacaux et al. 2007)	0.66	0.976	0.714	< 0.01
Turb ₆	B4/B2 (Cox Jr et al. 1998)	0.80	0.735	0.536	< 0.01
NLTDI	(B3-B2)/(B3+B2) The authors	0.80	0.740	0.521	< 0.01

(Turb₅, Turb₆ and NLTDI) to verify their performance on the individual campaign data. These results are shown in Table 5 in which each line represents a dataset and the last line shows the coefficient of variation (ratio of standard deviation to the mean) of the beta weights of the regressions. Even though the two band regression (B2,B3) appear to perform better overall, the coefficients of variation are much larger than in the case of the indices which implies a more erratic behaviour and less robust models.

3.4 Chlorophyll results

The results of simple linear regression between chl-a measurements and reflectance data from the 10 bands of S-2 are shown in Table 6. Although B1 (433–453 nm) could be a good candidate for chl-a (and eventually for turbidity as well) because of its good penetration and being close to a chlorophyll absorption band (450–475 nm), its low resolution of 60 m

16 *Removed for double-blind peer review*

Table 5 Results of the feature ranking of both the best spectral band combination and the different Turbidity Indices including the blue-green Normalised Difference Low Turbidity Index (NDLTI) we are proposing.

Campaign	$\beta_1\rho B2 + \beta_2\rho B3$				Turb ₅			Turb ₆			$\frac{B3}{B2}$			$\frac{(B3-B2)}{(B3+B2)}$		
	r^2	RMSE	β	B2	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
All	0.90	0.518	-59.00	76.04	0.66	0.976	-3.31	0.80	0.7435	2.616	0.77	0.791	1.119	0.80	0.740	10.54
04/10/2019	0.90	0.238	-49.50	53.64	0.85	0.307	-2.439	0.82	0.337	1.189	0.87	0.292	0.623	0.94	0.198	6.408
31/05/2020	0.89	0.694	-379.63	-294.54	0.49	1.619	-3.913	0.79	1.037	3.580	0.66	1.323	1.326	0.70	1.227	10.359
06/05/2021	0.98	0.198	-83.46	96.60	0.91	0.427	-3.139	0.97	0.239	2.787	0.96	0.282	1.0576	0.97	0.236	9.093
20/06/2021	0.97	0.129	-13.72	38.57	0.90	0.274	-1.887	0.91	0.252	1.932	0.92	0.238	0.727	0.85	0.344	8.502
24/08/2021	0.97	0.128	-86.513	92.898	0.83	0.314	-1.616	0.87	0.278	1.538	0.87	0.269	0.596	0.94	0.176	7.003
23/09/2021	0.96	0.474	-112.14	131.37	0.88	0.881	-6.712	0.90	0.792	4.082	0.93	0.670	1.977	0.96	0.510	20.539
28/10/2021	0.95	0.391	-120.90	117.32	0.80	0.783	-4.489	0.92	0.474	2.521	0.91	0.510	1.234	0.91	0.528	10.271
Coef. Var.			-1.000	0.714			-0.478			0.387			0.422			0.426

Colour code : $| r^2 > 0.90 | r^2 : 0.80-0.89 | r^2 : 0.70-0.79 | r^2 : 0.60-0.69 | r^2 < 0.60 |$



Figure 7: Strong banding effect in Sentinel-2 band 1 (coastal/aerosols).

and banding problem (Warren et al. 2019) especially visible in this band (Figure 7) made us drop its inclusion.

As expected, no regression between chl-a and a single spectral band produced a strong coefficient of determination (Table 6). The strongest r^2 (0.46–0.57) were obtained with the three visible bands mostly because the radiation in these bands can better penetrate water. Band 4 (red, 650–680 nm) should respond well to chl-a for being a strong absorption band of chl-a (and chl-b) without suffering the atmospheric attenuation affecting the coastal and blue bands. The remaining bands of red edge, NIR and SWIR all produced similar r^2 between 0.36 and 0.41.

Other sensors like OLCI (Sentinel-3) and MERIS (Envisat) can be more effective in quantifying concentrations of chl-a and PC due to their exclusive band centred at 620 nm efficient for the development of bio-optical algorithms (Ogashawara 2019).

To complete our tests of simple linear regression, we tested seven different indices developed for the purpose of estimating chl-a concentrations (Table 7). These indices have been selected based on their relative 'popularity' and their capacity to produce good estimates of chl-a concentrations. It should be noted that these indices may have been developed in very different contexts and for eutrophic waters with higher chl-a concentrations. At most, four of these indices produced r^2 scores between 0.6 ($Chla_2$ and $Chla_6$) and 0.64 ($Chla_5$) with the Maximum Chlorophyll Index (MCI, $Chla_3$) scoring at 0.63. This however is for the joint dataset containing all the in situ measurements of seven different dates over two years. It still stands out that they performed better than any of the spectral bands taken individually.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 17

Multiple regression was then applied to all spectral bands to determine the best combinations as well as the bands with the most impact on the models. A 'knock-out' algorithm (Sambur 1975) was used to rank these features: on the first stage a multiple regression of all combinations of all but one bands are executed and then the band with the least impact (best result obtained without it) is withdrawn from the next phase which then does the same with the remaining bands and so on until only one band remains. Table 8 shows the results of these operations for the bundle dataset as well as for the individual campaigns. What is striking about the results (Table 8) is that the r^2 remains at relatively similar levels with the ten bands or a single band, at least for the individual field campaigns. Another interesting aspect is that the 'best' band (last remaining) is mostly B3 (three times) and B5 (twice). All four band models would include a visible band (B2–B4) and most would include a red edge band (B5–B7). Conversely, the bundle dataset would only produce a reasonable model with most S-2 bands. Other than that, the ranking of the spectral bands vary widely.

The analysis of these results made us conclude that, even in a relatively stable water environment, no unique model would provide good estimates in all situations. In that sense, the chl-a indices are probably a better option as they offer relatively stable results in all eight situations as suggested by the results in Table 9. From these tests, we retain that for both oligotrophic and mesotrophic states, the indices $Chla_3$, $Chla_5$ and $Chla_6$ have a better potential and similar behaviour.

3.5 On the variability of the turbidity and chl-a results

Table 10 shows the scores of these same three chl-a indices along with the RMSEs and the Beta (β) weights that resulted from these regressions and the last line shows the coefficient of variation of the β weights. These coefficients are even larger than the ones obtained for turbidity (see Table 5) and even though most r^2 scores are above 0.8, (and even above 0.9 in the case of turbidity) none of these indices can be used directly to give good numerical estimates of chl-a concentrations or turbidity. This observation should be considered in a context where all in situ measurements were acquired with a state-of-the-art (calibrated) multiparameter sonde within less than four hours of the S-2 images which were all cloudless and corrected for atmospheric effects with a proven effective algorithm (MAJA). In other words, despite the next-to-none environmental and technical conditions and in the same water body, the levels of chl-a and turbidity are such that these indices show a variability in the order of two to three times the values they are meant to represent.

4 Discussion: a compromise operational approach

The results presented in the previous sections and especially the observations made in Section 3.5 bring the disappointing outcome that in the case of the *Três Marias* Reservoir with an oligotrophic to mesotrophic condition, no regression model or indices of turbidity and chlorophyll-a is robust enough to be used directly without some calibration. This made us propose a compromise approach through which some in situ measurements will be needed to calibrate the models or indices being used in order for this remote sensing approach to be operational. This of course could change if other environmental data is included to construct a more robust and reliable model (i.e. water and air temperature, precipitation, sediment chemistry, etc.).

18 *Removed for double-blind peer review***Table 6** Performance of the individual spectral bands of S-2 for estimating concentration of chl-a.

ID	Band	r^2	RMSE	MAE	p-value
B2	$\rho B2$	0.53	1.416	0.877	< 0.01
B3	$\rho B3$	0.57	1.346	0.840	< 0.01
B4	$\rho B4$	0.46	1.511	1.025	< 0.01
B5	$\rho B5$	0.41	1.589	1.112	< 0.01
B6	$\rho B6$	0.36	1.651	1.179	< 0.01
B7	$\rho B7$	0.37	1.638	1.164	< 0.01
B8	$\rho B8$	0.36	1.654	1.184	< 0.01
B8A	$\rho B8A$	0.36	1.647	1.191	< 0.01
B11	$\rho B11$	0.37	1.638	1.201	< 0.01
B12	$\rho B12$	0.37	1.642	1.189	< 0.01

Table 7 Performance of different 'Indices' for estimating concentration of chl-a.

ID	Index	r^2	RMSE	MAE	p-value
<i>Chla₁</i>	$\frac{\rho B4}{\rho B8}$ (Flores-Anderson et al. 2020)	0.42	1.568	0.938	< 0.01
<i>Chla₂</i>	$\frac{\rho B2}{\rho B3}$ (Flores-Anderson et al. 2020)	0.60	1.305	0.816	< 0.01
<i>Chla₃</i>	$MCI = \rho B5 - 1005 [\rho B4 + \frac{(\rho B6 - \rho B4) * (B5 - B4)}{B6 - B4}]$ (Peppa et al. 2020)	0.63	1.254	0.782	< 0.01
<i>Chla₄</i>	$MPH = \rho B5 - \rho B4 - \frac{(\rho B8A - \rho B4) * (B5 - B4)}{B8A - B4}$ (Peppa et al. 2020)	0.46	1.513	1.029	< 0.01
<i>Chla₅</i>	$\frac{\rho B5}{\rho B4}$ (Ha et al. 2017)	0.64	1.240	0.784	< 0.01
<i>Chla₆</i>	$\rho B5 + (\frac{\rho B6}{\rho B4})$ (Ha et al. 2017)	0.60	1.298	0.829	< 0.01
<i>Chla₇</i>	$\rho B5 - (\frac{\rho B4 + \rho B6}{2})$ (Toming et al. 2016)	0.49	1.473	0.965	< 0.01

Table 8 Results of chl-a multiple regression combined with a 'knock-out' feature selection/ranking scheme. Each stage shows which feature can be excluded with the least effect on the r^2 coefficient. At the same time this shows the ranking of the features with the most 'impacting' (last standing) one on the last stage (10). Results with a '*' (band removed) are cause by an insufficient number of in situ measurements for the number of variables.

	Knock out feature ranking by in situ campaign - r^2 result									
	All	01/07/2019	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021		
1	B11 0.78	B2 *	B2 0.95	B11 0.99	B3 0.95	B11 0.81	B4 0.98	B4 0.93		
2	B8 0.78	B8 *	B4 0.96	B8 0.99	B8A 0.95	B2 0.82	B11 0.98	B2 0.93		
3	B7 0.77	B11 *	B11 0.96	B6 0.99	B11 0.96	B4 0.83	B8 0.98	B7 0.93		
4	B6 0.78	B12 *	B6 0.96	B3 0.99	B12 0.95	B6 0.84	B2 0.98	B5 0.93		
5	B8A 0.75	B5 0.41	B8A 0.95	B2 0.99	B4 0.95	B8A 0.84	B5 0.98	B6 0.94		
6	B5 0.69	B3 0.59	B12 0.95	B8A 0.98	B8 0.95	B8 0.83	B7 0.98	B8A 0.94		
7	B4 0.68	B8A 0.69	B8 0.93	B4 0.98	B2 0.95	B12 0.83	B6 0.98	B12 0.93		
8	B2 0.49	B6 0.68	B3 0.92	B12 0.97	B6 0.94	B7 0.83	B3 0.98	B11 0.93		
9	B12 0.45	B7 0.68	B7 0.86	B5 0.96	B7 0.92	B5 0.79	B12 0.97	B8 0.92		
10	B3 0.45	B4 0.68	B5 0.86	B7 0.95	B5 0.92	B3 0.79	B8A 0.97	B3 0.92		

*: these bands have been removed based on their known weak contribution for chl-a.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 19**Table 9** Coefficients of determination (r^2) obtained through simple linear regression between each Chl-a index and the in situ measurements for each field campaign and the bundle dataset.

Index	All	01/07/2019	04/10/2019	31/05/2020	06/05/2021	20/06/2021	24/08/2021	23/09/2021
<i>Chla</i> ₁	0.42	0.61	0.79	0.81	0.66	0.85	0.92	0.92
<i>Chla</i> ₂	0.60	0.61	0.70	0.98	0.82	0.87	0.96	0.88
<i>Chla</i> ₃	0.63	0.64	0.79	0.97	0.86	0.89	0.97	0.90
<i>Chla</i> ₄	0.46	0.70	0.85	0.72	0.91	0.82	0.95	0.89
<i>Chla</i> ₅	0.64	0.66	0.77	0.98	0.85	0.89	0.97	0.90
<i>Chla</i> ₆	0.60	0.63	0.73	0.95	0.77	0.89	0.96	0.87
<i>Chla</i> ₇	0.49	0.65	0.83	0.83	0.89	0.80	0.95	0.87

Table 10 Results of simple linear regression between chl-a measurements and the three chlorophyll indices showing the r^2 scores, the beta weights (β) and the RMSE of each model. The last row shows the coefficient of variation of the beta weights.

	<i>Chla</i> ₃ (MCI)			<i>Chla</i> ₅ (B5/B4)			<i>Chla</i> ₆ (B5+(B6/B4))		
	r^2	RMSE	β	r^2	RMSE	β	r^2	RMSE	β
Geral	0.63	1.254	-1.34E-03	0.64	1.24	2.089	0.60	1.298	2.6067
01/07/2019	0.64	1.987	-0.002761	0.66	1.923	3.603	0.63	2.018	5.3190
04/10/2019	0.79	1.983	-0.003297	0.77	2.121	4.923	0.73	2.296	5.7035
31/05/2020	0.97	0.1	-6.10E-04	0.98	0.096	1.0838	0.95	0.142	1.7139
06/05/2021	0.86	0.611	-1.39E-03	0.85	0.644	2.3012	0.77	0.803	3.5766
20/06/2021	0.89	0.396	-1.03E-03	0.89	0.389	1.4105	0.89	0.388	1.8720
24/08/2021	0.97	0.173	-1.00E-03	0.97	0.181	1.4982	0.96	0.197	1.8600
23/09/2021	0.90	0.505	-1.02E-03	0.90	0.512	1.6571	0.87	0.566	1.8314
Cef. Var.			-0.6109			0.5629			0.5346
Colour code:	$r^2 > 0.90$	$r^2: 0.80-0.89$	$r^2: 0.70-0.79$	$r^2: 0.60-0.69$					

In the meantime, we suggest that using at least two in situ points can make these models and indices much more reliable and significantly reduce their errors. Since our field campaigns were not programmed as such, we undertook to simulate such an approach with the in situ data we collected by using always the same two points (or their nearest) in the reservoir: one near the dam (usually the one with the clearest water) and one upstream near the confluence of the two main rivers that supply the reservoir: the *São Francisco* and the *Paraopeba* rivers.

Figure 8 shows these errors (differences between measured and observed values) by survey points of each survey. Table 11 shows the errors obtained by calibrating the NLTDI and the *Chl - a*₅ index using two points always situated in the same areas (downstream and upstream). These values are very similar to the one obtained by performing individual linear regression for each in situ campaign with all the measurements collected (between 7 and 30 points). The map results for the lowest and highest conditions among the field campaigns for both the turbidity and chlorophyll-a are shown in Figure 9. These maps were produced using the calibrated versions of the NLTDI and *Chla*₅ indices.

4.1 Testing the approach on another reservoir

To put our approach to test, we acquired WQ data from another reservoir: *Várzea das Flores* situated only 40 km from the capital city of Belo Horizonte (Minas Gerais). Although this is a water supply reservoir (as opposed to hydroelectric like *Três Marias*), its quality is

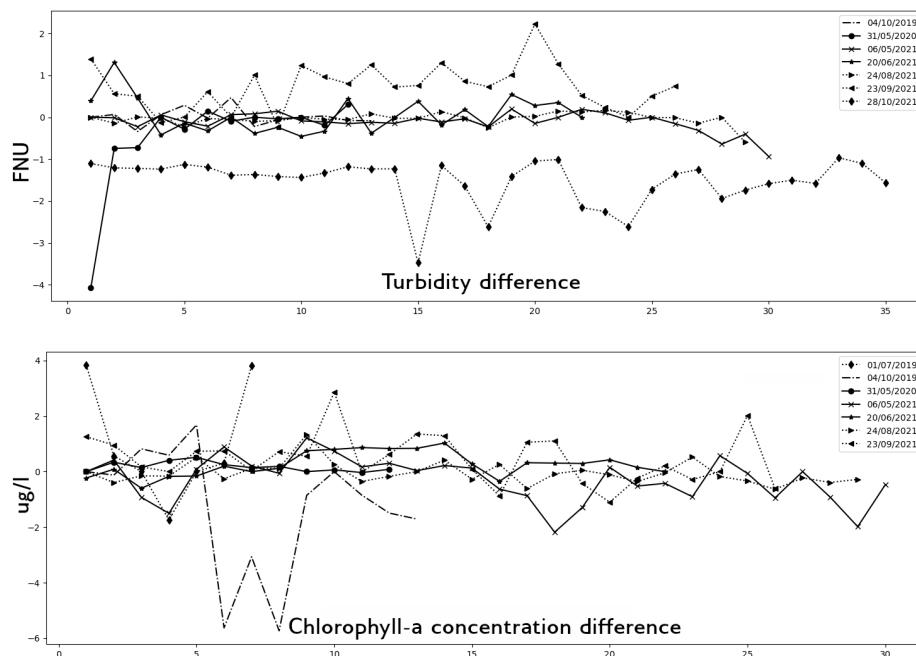
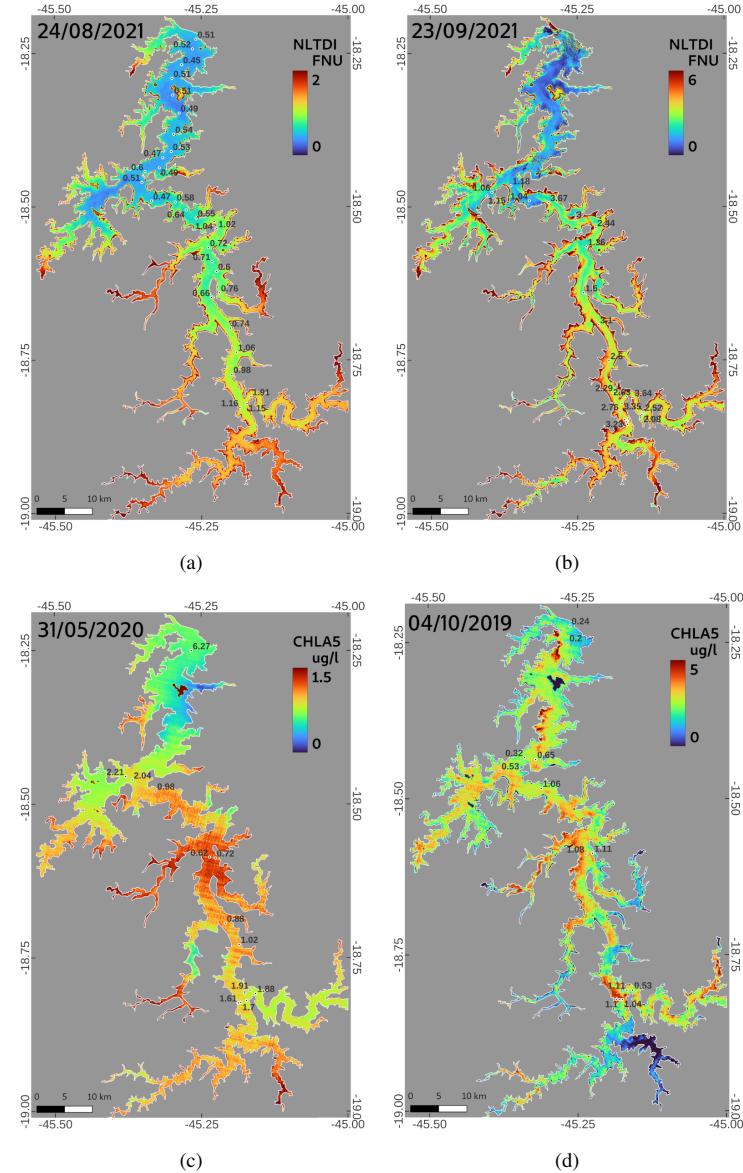


Figure 8: Graphs showing the differences between the measured turbidity and chlorophyll-a concentrations and the values obtained by calibrating the S-2 data indices.

Table 11 Root mean square errors and maximum absolute errors obtained for turbidity and chlorophyll-a values after calibrating the normalised low turbidity difference index (NLTDI) and the $Chl - a_5$ index (B5/B4) using two in situ measurement points. The 28/10/2021 campaign was excluded because no measurements were made near the 'standard' point adopted.

Turbidity	1/7/2019	4/10/2019	31/5/2020	6/5/2021	20/6/2021	24/8/2021	23/9/2021	Mean
RMSE (FNU)	No data	0.1948	1.1749	0.2563	0.4265	0.1491	0.9068	0.5181
MAE (FNU)	No data	0.1324	0.5270	0.1696	0.3379	0.0914	0.7518	0.3350
Chl-a								
RMSE ($\mu\text{g/l}$)	2.1621	2.5476	0.2480	0.8452	0.5056	0.3953	0.9947	1.1000
MAE ($\mu\text{g/l}$)	1.4673	1.7343	0.1916	0.6275	0.4003	0.2965	0.7445	0.7803



22 *Removed for double-blind peer review*

Table 12 A comparison between applying linear regression and two-point calibration in the *Várzea das Flores* Reservoir.

Index	Linear Regression		Linear Regression after the two-point calibration
Turbidity (NLTDI)	r^2	0.611	0.628
	RMSE	6.1688	2.4616
	MAE	1.4389	1.5005
Turbidity ($Turb_6$)	r^2	0.883	0.884
	RMSE	1.8495	1.8211
	MAE	1.0957	1.4527
Chlorophyll-a ($Chla_5$)	r^2	0.479	0.807
	RMSE	4.6309	0.7820
	MAE	1.9937	0.5857

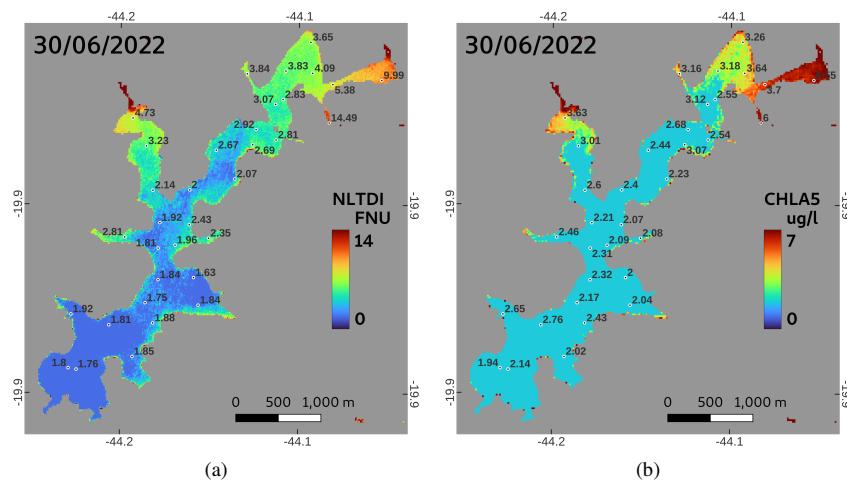


Figure 10: Maps of turbidity and chlorophyll-a in the *Várzea das Flores* Reservoir; (a) turbidity, (b) chl-a concentration. These map were produced using the two-points calibrated indices NLTDI and $Chla_5$.

quite inferior as it appears to be constantly mesotrophic. The survey made on 30 June 2022 resulted in turbidity values as high as 14 FNU and chl-a concentrations of almost $7 \mu\text{g/l}$ (Figure 10). Table 12 shows the r^2 scores along with the RMSE and MAE errors obtained firstly through simple linear regression between the in situ values of turbidity and chl-a and the indices of turbidity (NLTDI) and chl-a ($Chla_5$) on the left and secondly by first applying the two-point calibration before the regression (right). Interestingly the errors of the two-point calibration are smaller or at least similar ($Turb_6$) than with the straight regression. In this case, however, the $Turb_6$ index performed better than the NLTDI we created, which confirms that the latter is appropriate for low turbidity conditions.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 23

5 Conclusion

In this paper we aimed to find an effective way to transform Sentinel-2 data into estimates of turbidity and chlorophyll-a concentrations with the best accuracy using empirical approaches. In particular we wanted to determine which spectral bands and/or indices were the most promising for a water body with an oligotrophic to mesotrophic conditions. Our goal was also conditioned by defining an operational method usable by agencies managing reservoirs. For this goal we propose that if only S-2 data is to be used, the best approach consists in calibrating the data with two in situ measurements at opposite sides of the dynamic range (or close to it). The following points outline our main findings.

- Estimates of turbidity are simpler and generally more accurate than chlorophyll-a.
- For low turbidity conditions the NLTDI we created using S-2 bands B3 (green) and B2 (blue) provides good results and is well adapted to these conditions.
- Three chlorophyll-a indices have proven to provide reasonable estimates of chl-a concentrations including the maximum chlorophyll index (MCI) and the simple red edge to red ratio (B5/B4).
- Scores of r^2 are considerably reduced when the models are build with the bundle dataset that included seven different surveys performed over three years.
- No turbidity or chl-a model is robust enough to be directly applied to other water bodies nor other dates without regression adjustment or calibration.
- A two-point calibration approach is proposed to generate accurate estimates with reduced logistics.

Acknowledgments

Removed for double-blind peer review

Notes on contributors

Removed for double-blind peer review

References

- Abdelmalik, K. W. (2018), ‘Role of statistical remote sensing for inland water quality parameters prediction’, *The Egyptian Journal of Remote Sensing and Space Science* **21**(2), 193–200.
- Ackermann, W. C., White, G. F., Worthington, E. B. & Ivens, J. L. (1973), ‘Man-made lakes: their problems and environmental effects’, *Washington DC American Geophysical Union Geophysical Monograph Series*.

24 *Removed for double-blind peer review*

- Alparslan, E., Coskun, H. G. & Alganci, U. (2010), 'An investigation on water quality of Darlik Dam drinking water using satellite images', *The Scientific World Journal* **10**, 1293–1306.
- Anper, A. & Alikas, K. (2019), 'Retrieval of chlorophyll a from Sentinel-2 MSI data for the European Union water framework directive reporting purposes', *Remote Sensing* **11**(1), 64.
- Avdan, Z. Y., Kaplan, G., Goncu, S. & Avdan, U. (2019), 'Monitoring the water quality of small water bodies using high-resolution remote sensing data', *ISPRS International Journal of Geo-Information* **8**(12), 553.
- Barbosa, C. C. F., Novo, E. M. L. M. & Martins, V. S. (2019), *Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações*, Vol. 1, Instituto Nacional de Pesquisas Espaciais.
- Binding, C., Greenberg, T. & Bukata, R. (2013), 'The MERIS Maximum Chlorophyll Index; its merits and limitations for inland water algal bloom monitoring', *Journal of Great Lakes Research* **39**, 100–107.
- Bonansea, M., Rodriguez, C. & Pinotti, L. (2018), 'Assessing the potential of integrating Landsat sensors for estimating chlorophyll-a concentration in a reservoir', *Hydrology Research* **49**(5), 1608–1617.
- Bresciani, M., Cazzaniga, I., Austoni, M., Sforzi, T., Buzzi, F., Morabito, G. & Giardino, C. (2018), 'Mapping phytoplankton blooms in deep subalpine lakes from Sentinel-2A and Landsat-8', *Hydrobiologia* **824**(1), 197–214.
- Bresciani, M., Pinardi, M., Free, G., Luciani, G., Ghebrehiwot, S., Laanen, M., Peters, S., Della Bella, V., Padula, R. & Giardino, C. (2020), 'The use of multisource optical sensors to study phytoplankton spatio-temporal variation in a shallow turbid lake', *Water* **12**(1), 284.
- Brezonik, P., Menken, K. D. & Bauer, M. (2005), 'Landsat-based remote sensing of lake water quality characteristics, including chlorophyll and colored dissolved organic matter (CDOM)', *Lake and Reservoir Management* **21**(4), 373–382.
- Canfield Jr, D. E., Langeland, K. A., Maceina, M. J., Haller, W. T., Shireman, J. V. & Jones, J. R. (1983), 'Trophic state classification of lakes with aquatic macrophytes', *Canadian Journal of Fisheries and Aquatic Sciences* **40**(10), 1713–1718.
- Chen, J., Zhu, W.-N., Tian, Y. Q. & Yu, Q. (2017), 'Estimation of colored dissolved organic matter from Landsat-8 imagery for complex inland water: case study of Lake Huron', *IEEE Transactions on Geoscience and Remote Sensing* **55**(4), 2201–2212.
- Cheng, C., Wei, Y., Lv, G. & Yuan, Z. (2013), 'Remote estimation of chlorophyll-a concentration in turbid water using a spectral index: a case study in Taihu Lake, China', *Journal of Applied Remote Sensing* **7**(1), 073465.
- Cox Jr, R. M., Forsythe, R. D., Vaughan, G. E. & Olmsted, L. L. (1998), 'Assessing water quality in Catawba River Reservoirs using Landsat Thematic Mapper satellite data', *Lake and Reservoir Management* **14**(4), 405–416.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 25

- Curtarelli, V. P. (2020), Parametrização de algoritmos semi-analíticos para estimativa do coeficiente de atenuação difusa espectral (Kd) do Reservatório de Três Marias por sensoriamento remoto, Master's thesis, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, Brazil.
- Curtarelli, V. P., Barbosa, C. C., Maciel, D., Flores Júnior, R., Carlos, F., de Novo, E. M. L., Curtarelli, M. P. & Silva, E. F. F. (2020), 'Diffuse attenuation of clear water tropical reservoir: A remote sensing semi-analytical approach', *Remote Sensing* **12**(17), 1–23.
- Elhag, M., Gitas, I., Othman, A., Bahrawi, J. & Gikas, P. (2019), 'Assessment of water quality parameters using temporal remote sensing spectral reflectance in arid environments, Saudi Arabia', *Water* **11**(3), 556.
- Flores-Anderson, A. I., Griffin, R., Dix, M., Romero-Oliva, C. S., Ochaeta, G., Skinner-Alvarado, J., Ramirez Moran, M. V., Hernandez, B., Cherrington, E., Page, B. et al. (2020), 'Hyperspectral satellite remote sensing of water quality in Lake Atitlán, Guatemala', *Frontiers in Environmental Science* **8**, 7.
- Giardino, C., Bresciani, M., Cazzaniga, I., Schenk, K., Rieger, P., Braga, F., Matta, E. & Brando, V. E. (2014), 'Evaluation of multi-resolution satellite sensors for assessing water quality and bottom depth of Lake Garda', *Sensors* **14**(12), 24116–24131.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R. (2017), 'Google earth engine: Planetary-scale geospatial analysis for everyone', *Remote Sensing of Environment* **202**, 18–27.
- Ha, N. T. T., Thao, N. T. P., Koike, K. & Nhuan, M. T. (2017), 'Selecting the best band ratio to estimate chlorophyll-a concentration in a tropical freshwater lake using Sentinel 2A images from a case study of Lake Ba Be (Northern Vietnam)', *ISPRS International Journal of Geo-Information* **6**(9), 290.
- Hagolle, O., Colin, J., Coustance, S., Kettig, P., d'Angelo, P., Auer, S., Doxani, G. & Desjardins, C. (2021), 'Sentinel-2 surface reflectance products generated by cnes and dlr: methods, validation and applications', *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* **V-1-2021**, 9–15.
- Huo, A., Zhang, J., Qiao, C., Li, C., Xie, J., Wang, J. & Zhang, X. (2014), 'Multispectral remote sensing inversion for city landscape water eutrophication based on Genetic Algorithm-Support Vector Machine', *Water Quality Research Journal of Canada* **49**(3), 285–293.
- Jensen, J. (2014), *Remote Sensing of the Environment: An Earth Resource Perspective*, Prentice Hall series in geographic information science, Pearson Prentice Hall, Essex, United Kingdom, chapter Remote Sensing of Water, pp. 417–456.
- Jiang, G., Liu, D., Song, K., Wang, Z., Zhang, B. & Wang, Y. (2010), 'Application of multivariate model based on three simulated sensors for water quality variables estimation in Shitoukoumen Reservoir, Jilin province, China', *Chinese Geographical Science* **20**(4), 337–344.
- Kapalanga, T. S., Hoko, Z., Gumindoga, W. & Chikwiramakomo, L. (2021), 'Remote-sensing-based algorithms for water quality monitoring in Olushandja Dam, north-central Namibia', *Water Supply* **21**(5), 1878–1894.

26 *Removed for double-blind peer review*

- Lacaux, J., Tourre, Y., Vignalles, C., Ndione, J. & Lafaye, M. (2007), 'Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley fever epidemics in Senegal', *Remote Sensing of Environment* **106**(1), 66–74.
- Lechner, B., Liermann, C., Revenga, C., Vörösmarty, C., Fekete, B., Crouzet, P., Döll, P., Endejan, M., Frenken, K., Magome, J. et al. (2011), 'High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management', *Frontiers in Ecology and the Environment* **9**(9), 494–502.
- Malahela, O. E., Oliphant, T., Tsoeleng, L. T. & Mhangara, P. (2018), 'Mapping chlorophyll-a concentrations in a cyanobacteria- and algae-impacted Vaal Dam using Landsat 8 OLI data', *South African Journal of Science* **114**(9-10), 1–9.
- Mancino, G., Nolè, A., Urbano, V., Amato, M. & Ferrara, A. (2009), 'Assessing water quality by remote sensing in small lakes: the case study of Monticchio lakes in southern Italy', *iForest-Biogeosciences and Forestry* **2**(4), 154.
- Matthews, M. W. (2011), 'A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters', *International Journal of Remote Sensing* **32**(21), 6855–6899.
- Matthews, M. W., Bernard, S. & Robertson, L. (2012), 'An algorithm for detecting trophic status (chlorophyll-a), cyanobacterial-dominance, surface scums and floating vegetation in inland and coastal waters', *Remote Sensing of Environment* **124**, 637–652.
- Menken, K. D., Brezonik, P. L. & Bauer, M. E. (2006), 'Influence of chlorophyll and colored dissolved organic matter (CDOM) on lake reflectance spectra: Implications for measuring lake properties by remote sensing', *Lake and Reservoir Management* **22**(3), 179–190.
- Odermatt, D., Heege, T., Nieke, J., Kneubühler, M. & Itten, K. (2008), 'Water quality monitoring for Lake Constance with a physically based algorithm for MERIS data', *Sensors* **8**(8), 4582–4599.
- Ogashawara, I. (2019), 'The use of Sentinel-3 imagery to monitor cyanobacterial blooms', *Environments* **6**(6), 60.
- Ouma, Y. O., Noor, K. & Herbert, K. (2020), 'Modelling reservoir chlorophyll-a, tss, and turbidity using sentinel-2a msi and landsat-8 oli satellite sensors with empirical multivariate regression', *Journal of Sensors*.
- Peppa, M., Vasilakos, C. & Kavroudakis, D. (2020), 'Eutrophication monitoring for Lake Pamvotis, Greece, using Sentinel-2 data', *ISPRS International Journal of Geo-Information* **9**(3), 143.
- Potes, M., Costa, M. J. & Salgado, R. (2012), 'Satellite remote sensing of water turbidity in Alqueva Reservoir and implications on lake modelling', *Hydrology & Earth System Sciences*.
- Pyo, J. C., Ligaray, M., Kwon, Y. S., Ahn, M. H., Kim, K., Lee, H., Kang, T., Cho, S. B., Park, Y. & Cho, K. H. (2018), 'High-spatial resolution monitoring of phycocyanin and chlorophyll-a using airborne hyperspectral imagery', *Remote Sensing* **10**(8), 1180.

Sentinel-2 indices for turbidity and chlorophyll-a for a reservoir in Brazil 27

- Quang, N. H., Sasaki, J., Higa, H. & Huan, N. H. (2017a), 'Spatiotemporal variation of turbidity based on Landsat 8 OLI in Cam Ranh Bay and Thuy Trieu Lagoon, Vietnam', *Water* **9**(8), 570.
- Quang, N. H., Sasaki, J., Higa, H. & Huan, N. H. (2017b), 'Spatiotemporal variation of turbidity based on landsat 8 oli in cam ranh bay and thuy trieu lagoon, vietnam', *Water*.
- Ritchie, J. C., Cooper, C. M. & Schiebe, F. R. (1990), 'The relationship of MSS and TM digital data with suspended sediments, chlorophyll, and temperature in Moon Lake, Mississippi', *Remote Sensing of environment* **33**(2), 137–148.
- Robert, E., Kergoat, L., Soumaguel, N., Merlet, S., Martinez, J. M., Diawara, M. & Grippa, M. (2017), 'Analysis of suspended particulate matter and its drivers in Sahelian ponds and lakes by remote sensing (Landsat and MODIS): Gourma region, Mali', *Remote Sensing* **9**(12), 1272.
- Rodrigues, T., Alcântara, E., Watanabe, F. & Imai, N. (2017), 'Retrieval of Secchi disk depth from a reservoir using a semi-analytical scheme', *Remote Sensing of Environment* **198**, 213–228.
- Sabat-Tomala, A., Jarocińska, A. M., Zagajewski, B., Magnuszewski, A. S., Ślawik, Ł. M., Ochtyra, A., Raczkowski, E. & Lechnio, J. R. (2018), 'Application of HySpex hyperspectral images for verification of a two-dimensional hydrodynamic model', *European Journal of Remote Sensing* **51**(1), 637–649.
- Sambur, M. (1975), 'Selection of acoustic features for speaker identification', *IEEE Transactions on Acoustics, Speech, and Signal Processing* **23**(2), 176–182.
- Silva, H. A. N., Naranjo, P. G. V., Rodrigues, L. P. S., Araújo, D. M. & Pires, Y. P. (2020), 'Prediction of some physico-chemical parameters of water in Alton Reservoir, Suffolk, England', *WSEAS Transactions on Environment and Development* **16**, 119–131.
- Soomets, T., Uudeberg, K., Jakovels, D., Brauns, A., Zagars, M. & Kutser, T. (2020), 'Validation and comparison of water quality products in baltic lakes using Sentinel-2 MSI and Sentinel-3 OLCI data', *Sensors* **20**(3), 742.
- Toming, K., Kutser, T., Laas, A., Sepp, M., Paavel, B. & Nõges, T. (2016), 'First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery', *Remote Sensing* **8**(8), 640.
- Torbick, N., Ziniti, B., Stommel, E., Linder, E., Andrew, A., Caller, T., Haney, J., Bradley, W., Henegan, P. L. & Shi, X. (2018), 'Assessing cyanobacterial harmful algal blooms as risk factors for amyotrophic lateral sclerosis', *Neurotoxicity research* **33**(1), 199–212.
- Torres-Bejarano, F., Arteaga-Hernández, F., Rodríguez-Ibarra, D., Mejía-Ávila, D. & González-Márquez, L. (2021), 'Water quality assessment in a wetland complex using Sentinel 2 satellite images', *International Journal of Environmental Science and Technology* **18**(8), 2345–2356.
- Tu, M., Smith, P. & Filippi, A. M. (2018), 'Hybrid forward-selection method-based water-quality estimation via combining Landsat TM, ETM+, and OLI/TIRS images and ancillary environmental data', *PloS one*.

28 *Removed for double-blind peer review*

- Uudeberg, K., Aavaste, A., Kõks, K., Ansper, A., Uusõue, M., Kangro, K., Ansko, I., Ligi, M., Toming, K. & Reinart, A. (2020), 'Optical water type guided approach to estimate optical water quality parameters', *Remote Sensing* **12**(6), 931.
- Wang, X., Song, K., Wen, Z., Liu, G., Shang, Y., Fang, C., Lyu, L. & Wang, Q. (2021), 'Quantifying turbidity variation for lakes in Daqing of Northeast China using landsat images from 1984 to 2018', *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **14**, 8884–8897.
- Warren, M. A., Simis, S. G., Martinez-Vicente, V., Poser, K., Bresciani, M., Alikas, K., Spyракος, E., Giardino, C. & Ansper, A. (2019), 'Assessment of atmospheric correction algorithms for the sentinel-2a multispectral imager over coastal and inland waters', *Remote sensing of environment* **225**, 267–289.
- Watanabe, F., Alcantara, E., Rodrigues, T., Rotta, L., Bernardo, N. & Imai, N. (2018), 'Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita Reservoir, Brazil)', *Anais da Academia Brasileira de Ciências* **90**(2), 1987–2000.
- Wetzel, R. G. (2001), *Limnology: lake and river ecosystems*, third edn, Gulf Professional Publishing, San Diego, USA, chapter Structure and productivity of aquatic ecosystems, pp. 129–150.
- Wilkie, C. J., Miller, C. A., Scott, E. M., O'Donnell, R. A., Hunter, P. D., Spyракος, E. & Tyler, A. N. (2019), 'Nonparametric statistical downscaling for the fusion of data of different spatiotemporal support', *Environmetrics* **30**(3), e2549.
- Xu, X., Huang, X., Zhang, Y. & Yu, D. (2018), 'Long-term changes in water clarity in Lake Liangzi determined by remote sensing', *Remote sensing* **10**(9), 1441.
- Zeng, C. & Binding, C. (2019), 'The effect of mineral sediments on satellite chlorophyll-a retrievals from line-height algorithms using red and near-infrared bands', *Remote Sensing* **11**(19), 2306.