

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 estimação 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 fúlvicos, 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).

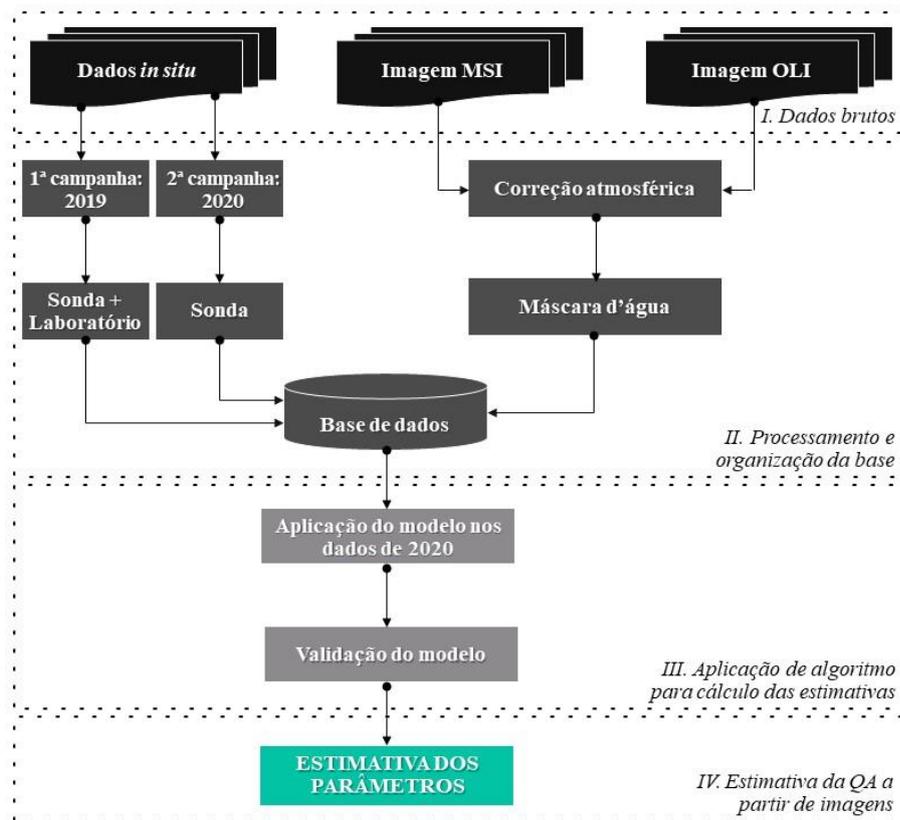
Neste artigo, utilizou-se a capacidade de estimar três parâmetros NOA de qualidade da água por meio de análises estatísticas associadas ao sensoriamento remoto passivo. Dados de sensores remotos provenientes dos satélites Landsat-8 e Sentinel-2 foram empregados de forma a estimar os níveis de qualidade 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.

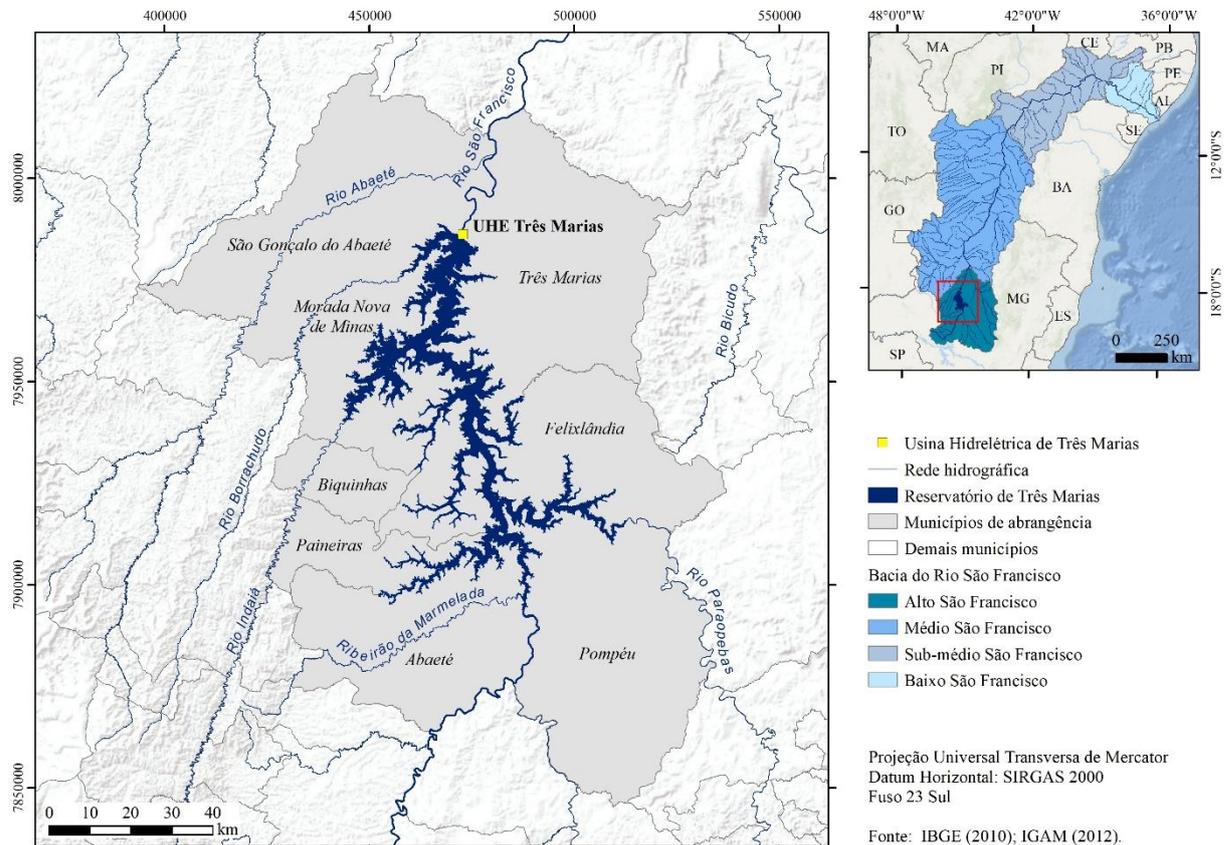
As especificidades das etapas descritas serão abordadas nos subtópicos que se seguem.

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.

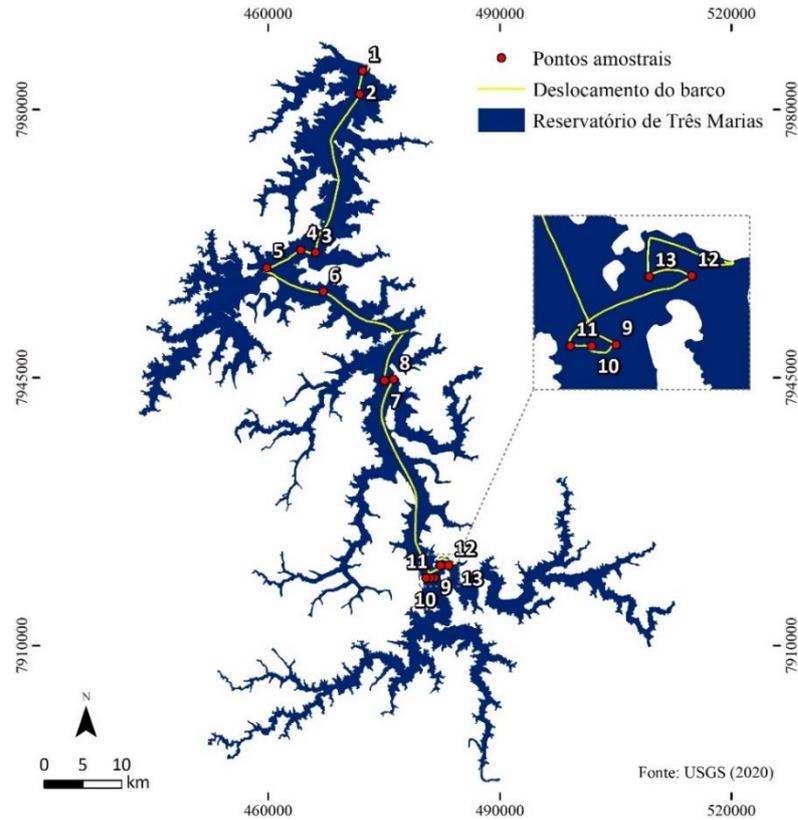
Ambas as campanhas foram idealizadas de acordo com a coincidência de datas quanto à passagem dos satélites Sentinel-2 e Landsat-8, que seriam sincronizados com as coletas em campo. Os dois satélites se coincidem a cada 80 dias e suas passagens ocorrem por volta das 10h00 da manhã (horário local). Desta 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 irrisória 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. <i>Red edge</i> 1	698 – 713	20
			B6. <i>Red edge</i> 2	733 – 748	20
			B7. <i>Red edge</i> 3	773 – 793	20
B5. Infravermelho próximo (NIR)	845 – 885	30	B8. Infravermelho próximo (NIR)	785 – 900	10
			B8A. <i>Red edge</i> 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::

$$NDWI = (\rho(verde) - \rho(NIR)) \div (\rho(verde) + \rho(NIR))$$

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 de 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	r²
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	r²
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	r²
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	r²
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 ópticamente 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 -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.

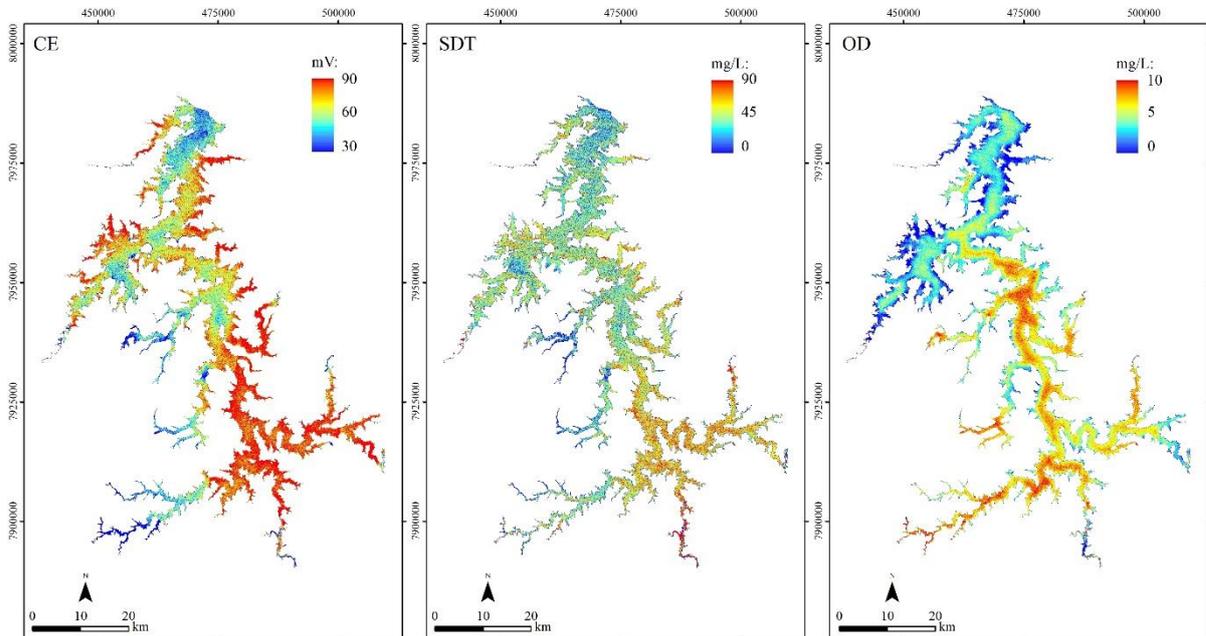
Sentinel-2/MSI								
Parâmetro	04/10/2019				31/05/2020			
	r^2	MAE	RMSE	p -value	r^2	MAE	RMSE	p -value
CE	0,76	3,70	4,87	0,01	0,78	0,68	0,88	< 0,01
SDT	0,89	< LD	12,3	0,03	0,71	0,31	0,39	0,12
OD	0,83	0,06	0,08	< 0,01	0,81	0,13	0,17	< 0,01
Landsat-8/OLI								
Parâmetro	04/11/2019				31/05/2020			
	r^2	MAE	RMSE	p -value	r^2	MAE	RMSE	p -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).

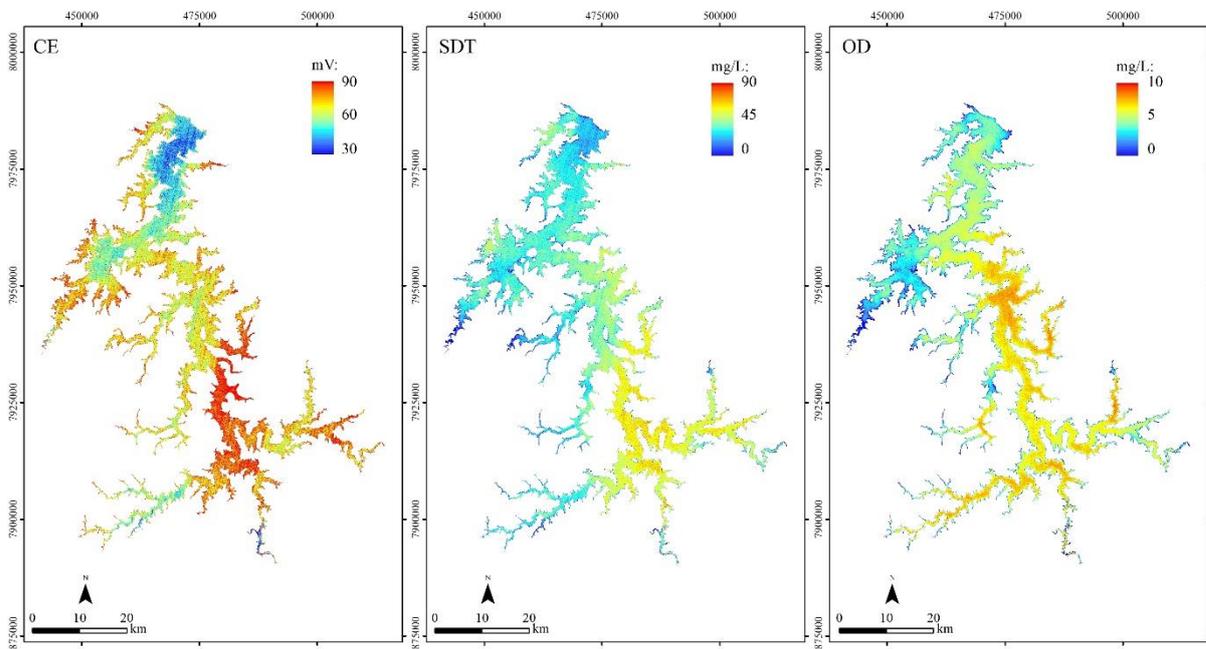
As Figuras 4 e 5 ilustram os mapas que foram gerados para os modelos de CE, SDT e OD com o uso dos sensores MSI e OLI, respectivamente.

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-ópticamente 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, conseqüentemente, 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 Egyptian 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_AproveitamentoTr%C3%AAsMarias_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%AAsMarias_2020_MAIO_KDL_AC_LB.pdf. Acesso em: 01 mar. 2021.

CETESB – Companhia Ambiental do Estado de São Paulo. **Relatório de Qualidade das Águas Interiores 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-interiores/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.; NÖGES, 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/UFMG, 1999.

VON SPERLING, M. **Introdução à qualidade das águas e ao tratamento de esgotos**. 4 ed. Belo Horizonte: DESA/UFMG, 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/ijmsmer.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/ijmsmer.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