



Definição de regiões para caracterização e monitoramento da Represa de Várzea das Flores, Minas Gerais

Vinícius Lima Guimarães¹, Antonio Miguel Vieira Monteiro², Eduardo Celso Gerbi Camargo³, Milton Kampel⁴

¹ Mestrando do Programa de Pós-graduação em Sensoriamento Remoto (PGSER), Coordenação de Ensino, Pesquisa e Extensão (COEPE), Instituto Nacional de Pesquisas Espaciais (INPE), Av. dos Astronautas, 1758, CEP 12227-010, São José dos Campos, São Paulo. Email: vinicius.lima@inpe.br; <https://orcid.org/0000-0003-0686-8321>. ² Tecnologista Sênior III, Divisão de Observação da Terra e Geoinformática (DIOTG), Coordenação Geral de Ciências da Terra (CG-CT), Instituto Nacional de Pesquisas Espaciais (INPE), Av. dos Astronautas, 1758, CEP 12227-010, São José dos Campos, São Paulo. Email: miguel.monteiro@inpe.br; <https://orcid.org/0000-0003-1477-1749>. ³ Tecnologista Sênior III, Divisão de Observação da Terra e Geoinformática (DIOTG), Coordenação Geral de Ciências da Terra (CG-CT), Instituto Nacional de Pesquisas Espaciais (INPE), Av. dos Astronautas, 1758, CEP 12227-010, São José dos Campos, São Paulo. Email: eduardo.camargo@inpe.br; <https://orcid.org/0000-0001-9088-1072>. ⁴ Pesquisador Titular III, Divisão de Observação da Terra e Geoinformática (DIOTG), Coordenação Geral de Ciências da Terra (CG-CT), Instituto Nacional de Pesquisas Espaciais (INPE), Av. dos Astronautas, 1758, CEP 12227-010, São José dos Campos, São Paulo. Email: milton.kampel@inpe.br; <https://orcid.org/0000-0002-0011-2083>.

Artigo recebido em 25/06/2025 e aceito em 16/12/2025

RESUMO

Este estudo teve como objetivo regionalizar a represa de Várzea das Flores, em Minas Gerais, por meio de sensoriamento remoto e métodos estatísticos de análise de dados geoespaciais, de 2017 a 2024. Inaugurada em 1972 para atender à crescente demanda hídrica da Região Metropolitana de Belo Horizonte, a represa enfrenta problemas de qualidade da água, associados à ocupação e ao uso do solo em sua bacia hidrográfica. Para isso, foram aplicadas as técnicas de regionalização SKATER e K-Medoids para agrupar o espelho d'água em zonas homogêneas. A análise baseou-se em dados de batimetria, turbidez e temperatura de superfície da água. A temperatura de superfície foi obtida a partir das bandas no infravermelho termal dos sensores a bordo dos satélites da série Landsat. A batimetria foi obtida do banco de dados *Global lakes bathymetry dataset* (GLOBathy) e a turbidez foi estimada por meio de modelos semianalíticos, combinando imagens do satélite Sentinel-2 e amostras de campo. O método K-Medoids apresentou maior eficiência para o agrupamento de zonas homogêneas, sendo selecionado o número de três grupos, fundamentado nos critérios do método Elbow e do índice *Silhouette Score*. A análise multivariada de variância indicou diferenças sazonais significativas entre as zonas. Esses resultados contribuem para subsidiar ações de gestão e conservação da represa.

Palavras-chave: K-Medoids, SKATER, agrupamento, Várzea das Flores, turbidez.

Definition of regions for characterization and monitoring of the Várzea das Flores Reservoir, Minas Gerais

ABSTRACT

This study aimed to regionalize the Várzea das Flores reservoir, located in Minas Gerais, Brazil, using remote sensing and statistical methods for geospatial data analysis between 2017 and 2024. Inaugurated in 1972 to meet the growing water demand of the Metropolitan Region of Belo Horizonte, the reservoir currently faces water quality issues associated with land use and occupation in its watershed. To address this, the SKATER and K-Medoids clustering techniques were applied to group the water surface into homogeneous zones. The analysis was based on bathymetry, turbidity, and water surface temperature data. Surface temperature was derived from the thermal infrared bands of sensors onboard the Landsat satellite series. Bathymetry data were obtained from the Global Lakes Bathymetry Dataset (GLOBathy), and turbidity was estimated using semi-analytical models that combined Sentinel-2 satellite imagery and field samples. The K-Medoids method showed higher efficiency in grouping homogeneous zones, with three clusters selected based on the Elbow method and Silhouette Score criteria. Multivariate analysis of variance indicated significant seasonal differences among the zones. These results contribute to supporting management and conservation actions for the reservoir.

Keywords: K-Medoids, SKATER, clustering, Várzea das Flores, turbidity.

Introdução

O sensoriamento remoto constitui uma alternativa eficaz para o monitoramento de características biogeoquímicas e físicas de corpos d'água, oferecendo alta frequência temporal e maior viabilidade financeira e logística em comparação às análises *in situ* (Dutkiewicz et al., 2015; Martins et al., 2017; IOCCG, 2020; Khazaei et al., 2022; Xiong et al., 2023). Este subsidia a aplicação de diferentes técnicas de agrupamento voltadas à regionalização dos sistemas aquáticos (Carvalho et al., 2023; Cerutti et al., 2025). Esses procedimentos de regionalização têm como objetivo segmentar grandes objetos espaciais em unidades menores e homogêneas (Assunção et al., 2006; Aydin et al., 2021).

Técnicas de regionalização fornecem subsídios importantes para o planejamento e a gestão de sistemas aquáticos. Em termos práticos, permitem orientar ações prioritárias para conservação, bem como a alocação de recursos para mitigação de impactos ambientais (Evans et al., 2025; Meng et al., 2024; Wang et al., 2024). Dentre essas ações estão o controle de cargas difusas, intervenções a montante para restauração ambiental e o monitoramento espacialmente direcionado da poluição em lagos e reservatórios (Matsui & Kageyama, 2022; Kim et al., 2025).

As represas são influenciadas por diversos fatores que interagem de forma complexa, tais como o uso e cobertura do solo, a precipitação e a vazão em suas respectivas bacias hidrográficas (Taylor e Rising, 2021). Essa dinâmica é evidenciada na represa de Várzea das Flores, em Minas Gerais. Inaugurada em 1972, por meio de um convênio entre os municípios de Betim e Contagem, a represa foi concebida com o objetivo de atender à crescente demanda hídrica decorrente do adensamento urbano desses municípios. Atualmente, é responsável pelo abastecimento de aproximadamente 15% da Região Metropolitana de Belo Horizonte (Santos et al., 2018). Apesar de sua importância estratégica para o abastecimento hídrico regional, a qualidade da água da represa tem sido comprometida pela configuração do uso e ocupação do solo em sua bacia hidrográfica. Nesta, há uma urbanização desordenada, pressão do mercado imobiliário sobre áreas ambientalmente sensíveis e infraestrutura de esgotamento sanitário deficiente (Santos, 2012; Magalhães Júnior et al., 2016; Santos et al., 2018).

As abordagens mais utilizadas para a regionalização de sistemas aquáticos baseiam-se em técnicas de classificação supervisionada e não

supervisionada (Krug et al., 2017). Entre os métodos de classificação não supervisionada, destaca-se o K-Medoids como uma alternativa promissora. Proposto por Kaufman e Rousseeuw (1990), o K-Medoids define regiões a partir dos pontos de maior centralidade/representatividade entre as observações existentes. Este apresenta menor sensibilidade a *outliers* e ruídos em comparação ao K-médias, método amplamente empregado, que utiliza a média das observações como critério de agrupamento (Kaufman e Rousseeuw, 1990; Entezami et al., 2020; Ishak et al., 2024).

Assunção et al. (2006) destacam que técnicas de classificação supervisionada e não supervisionada tendem a gerar regiões que capturam de forma limitada as relações de adjacência e os padrões espaciais dos dados. Com base nessa limitação, os autores propuseram o método *Spatial 'K' Adaptive Tree* (SKATER) (Assunção et al., 2006). Este permite a criação de regiões espacialmente contínuas e interligadas, com base em relações de dissimilaridade extraídas de uma árvore mínima gerada a partir da adjacência entre geo-objetos. Embora originalmente desenvolvido para regionalização de variáveis socioeconômicas, o SKATER tem demonstrado robustez na aplicação a variáveis ambientais. Este método foi utilizado na delimitação de regiões climáticas (Ahmed et al., 2023), na identificação de rios com condições semelhantes de qualidade da água (Novianta et al., 2024) e no delineamento hierárquico de unidades populacionais de aves (O'Donell et al., 2019).

Além da diversidade de métodos disponíveis para a regionalização, diferentes variáveis podem ser utilizadas para a segmentação de sistemas aquáticos. Entre elas, destacam-se os espectros de reflectância (Vantrepotte et al., 2012; Mélin e Vantrepotte, 2015; Spyrakos et al., 2018; Wei et al., 2022), as características biogeoquímicas (Reygondeau et al., 2018; Rosso et al., 2020) e, no caso de águas costeiras e oceânicas, variáveis meteoceanográficas (Moreno et al., 2023).

Este trabalho tem como objetivo aplicar e comparar os métodos SKATER e K-Medoids na regionalização da represa de Várzea das Flores, no período de 2017 a 2024, considerando as estações de inverno e verão. São utilizadas variáveis obtidas por sensoriamento remoto, as quais incluem turbidez, temperatura de superfície da água e batimetria. A combinação dessas variáveis com métodos de regionalização de abordagens distintas,

aliada à consideração da variabilidade sazonal, configura uma abordagem inédita no contexto da represa estudada. Espera-se que as regiões identificadas no presente estudo possam contribuir para direcionar ações de monitoramento, definindo áreas prioritárias para o controle da entrada de sedimentos e matéria orgânica e da degradação da qualidade da água, bem como subsidiar a alocação eficiente de recursos.

Material e métodos

Área de estudo

Localizada na região central de Minas Gerais (Figura 1), a aproximadamente 30 km da

capital, Belo Horizonte, a represa de Várzea das Flores possui uma área de 3,76 km². Deste total, 54,43% encontram-se no município de Contagem, enquanto que os 45,57% restantes situam-se em Betim (ANA, 2021). A bacia hidrográfica associada à represa abrange uma área de 123,27 km². Esta se insere na porção média da Bacia Hidrográfica do Rio Paraopeba que, por sua vez, integra a bacia federal do Rio São Francisco (Santos, 2012; Magalhães Júnior et al., 2016). A região apresenta clima tropical de altitude, caracterizado por um verão chuvoso (de outubro a março) e um inverno seco (de abril a setembro) (Santos, 2012).

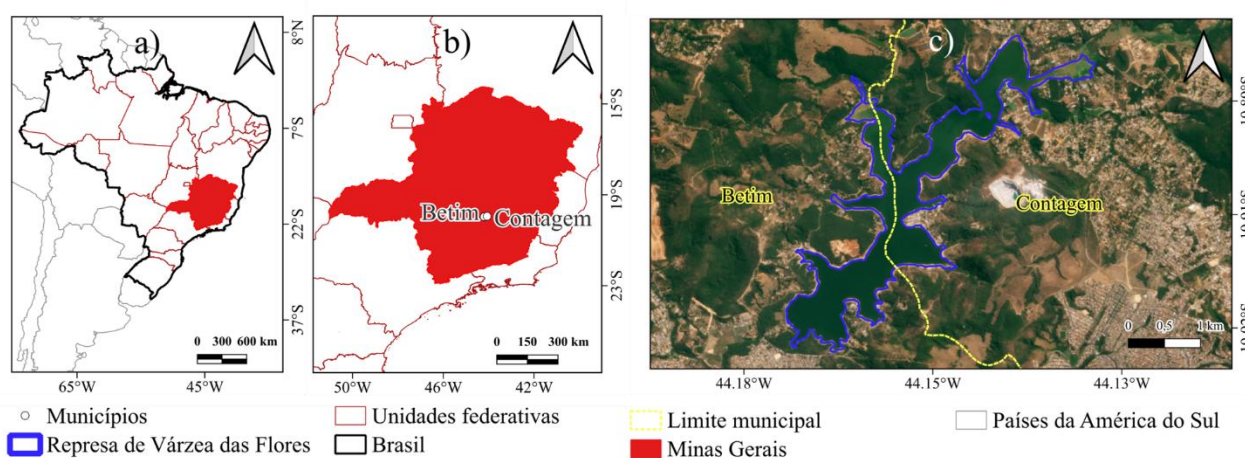


Figura 1. Contexto geográfico da área de estudo em diferentes escalas: (a) posição do estado de Minas Gerais no Brasil; (b) localização dos municípios de Contagem e Betim no estado de Minas Gerais; (c) localização da represa de Várzea das Flores, em uma imagem de alta resolução *PlanetScope* cor verdadeira de agosto de 2024.

Procedimentos metodológicos

A Figura 2 apresenta um fluxograma geral da metodologia adotada. Foram utilizadas todas as imagens de reflectância de superfície disponíveis para a área de estudo, provenientes do sensor *MultiSpectral Instrument* (MSI), a bordo dos satélites Sentinel 2A e 2B. As imagens foram obtidas a partir da plataforma *Amazon Web Services*, no nível de processamento L2A, com correção atmosférica pelo algoritmo *Sen2Cor* (Main-Knorn et al., 2017). Coletou-se imagens entre janeiro de 2017 e dezembro de 2024, com resolução temporal nominal de 5 dias.

A turbidez é uma medida indireta da atenuação óptica causada pela combinação do material orgânico dissolvido e material inorgânico particulado em suspensão (Dogliotti et al., 2015; Adjovu et al., 2023). Esta é passível de estimativa por sensoriamento remoto e considerada um

importante indicador de qualidade da água (Dogliotti et al., 2015; Adjovu et al., 2023). Neste estudo, foi selecionado algoritmo específico para estimar a turbidez na represa a partir de imagens do Sentinel 2, cujos resultados foram utilizados como uma das variáveis de entrada no processo de regionalização. A imagem do dia 30/06/2022, adquirida às 10:12 pelo satélite Sentinel-2A, foi utilizada para a estimativa da turbidez pela aplicação de dois algoritmos no estado da arte.

O primeiro algoritmo aplicado foi o proposto por Nechad et al. (2009). Desenvolvido com base em 49 amostras coletadas no Mar do Norte Meridional, trata-se de um algoritmo semianalítico. Neste se estabelece uma relação entre a refletância emergente da coluna d'água, em comprimentos de onda entre o vermelho e infravermelho próximo e os valores de turbidez medidos *in situ*. Essa relação é ajustada por meio

de coeficientes específicos para cada comprimento de onda (Nechad et al., 2009; 2010). A fórmula

utilizada para a aplicação do algoritmo é apresentada na Equação 1.

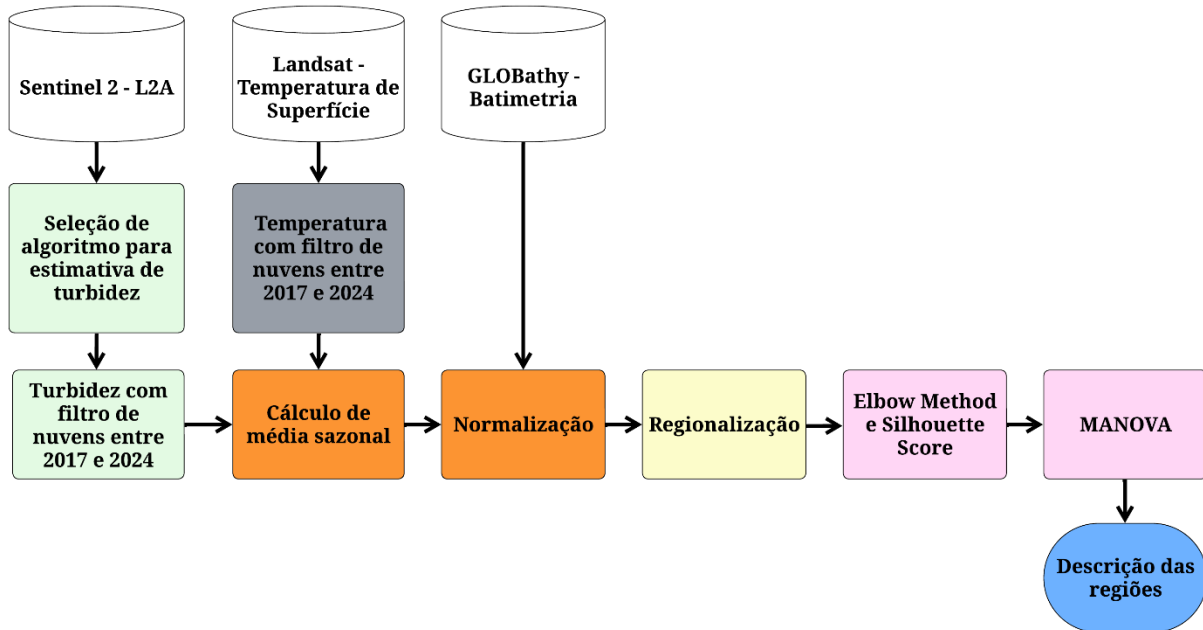


Figura 2. Fluxograma das etapas metodológicas desenvolvidas para as regionalizações de verão e inverno da represa de Várzea das Flores, MG, no período entre 2017 e 2024. As etapas de processamento são sintetizadas, desde o processo de aquisição dos dados orbitais de sensoriamento remoto e de modelagem de batimetria até o processo de descrição das regiões. Os blocos em branco representam os dados adquiridos. Em verde claro, são representadas as etapas adotadas para seleção e reprodução do algoritmo mais acurado para estimativa de turbidez a partir de imagens do sensor *MultiSpectral Instrument*, a bordo dos satélites Sentinel-2A e 2B. O bloco em cinza representa a etapa metodológica de filtragem de nuvem das estimativas de temperatura de superfície, as quais foram derivadas de imagens no infravermelho termal de sensores a bordo da série Landsat. Em laranja, são apresentadas as etapas de tratamento de dados adotadas para regionalização da represa, as quais incluíram o cálculo de média sazonal e normalização de turbidez e temperatura de superfície, além da normalização do dado de batimetria. O bloco amarelo representa a etapa de regionalização, em que os algoritmos *Spatial K'cluster Analysis by Tree Edge Removal* e *K-Medoids* foram testados. Os blocos em cor rosa representam as análises estatísticas realizadas para seleção do método de regionalização e da quantidade de regiões (*Elbow Method* e *Silhouette Score*), além da análise MANOVA para comparação das regionalizações sazonais. O último bloco, em azul, representa a etapa final, em que foi feita a análise descritiva das regiões obtidas.

$$T = \frac{A_T \rho_w(\lambda)}{1 - \rho_w(\lambda)/C_T} + B_T \quad (\text{Eq. 1})$$

onde: T é a turbidez estimada em Unidade Nefelométrica de Formazina (FNU, do inglês *Formazin Nephelometric Units*); ρ_w é a reflectância emergente da coluna d'água, em um comprimento de onda (λ); A_T é o coeficiente de calibração empírico usado para modelar a razão da absorção do material não particulado pelo retroespalhamento do material particulado, dependente do comprimento de onda; C_T é o coeficiente de calibração utilizado para modelar a razão do retroespalhamento do material particulado pela

absorção do material particulado; B_T é um termo de correção aditivo para compensação de erros na modelagem obtido por regressão não linear em conjunto com A_T .

O algoritmo foi aplicado às seis bandas do sensor MSI do satélites Sentinel-2A situadas no intervalo de comprimentos de onda do vermelho e do infravermelho próximo, utilizando os coeficientes de calibração apresentados por Nechad et al. (2009, 2010). As características de cada banda utilizada, bem como os respectivos valores dos coeficientes A_T , B_T e C_T , necessários para aplicação do algoritmo, são apresentados na Tabela 1. As diferentes versões do algoritmo foram nomeadas com base no comprimento de onda

central da banda correspondente (em nanômetros, nm).

Tabela 1 - Coeficientes de calibração (A_T , B_T e C_T) do algoritmo semianalítico de Nechad et al. (2009, 2010) para estimativa de turbidez, específicos para as bandas em diferentes comprimentos de onda do sensor *MultiSpectral Instrument*, a bordo do satélite Sentinel-2A e 2B. Esses coeficientes são utilizados para conversão da reflectância emergente da coluna d'água em valores de turbidez (FNU).

Denominação da aplicação por comprimento de onda central (nm)	Banda do <i>MultiSpectral Instrument</i>	Largura de banda (nm)	Resolução espacial (m)	A_T	B_T	C_T
N09 (665 nm)	B4	38	10	282,95	0,23	17,28
N09 (705 nm)	B5	19	20	345,20	0,26	18,79
N09 (740 nm)	B6	18	20	1149,39	0,02	19,73
N09 (783 nm)	B7	28	20	1283,76	0,06	20,55
N09 (842 nm)	B8	145	10	1835,04	0,02	21,06
N09 (865 nm)	B8A	33	20	2109,35	-0,02	21,15

O segundo algoritmo, proposto por Dogliotti et al. (2015), baseia-se na mesma premissa adotada por Nechad et al. (2009). Nele, se estabelece uma relação entre turbidez da água e a reflectância em comprimentos de onda situados entre o vermelho e o infravermelho próximo. No entanto, enquanto Nechad et al. (2009) utilizam apenas uma banda espectral para a estimativa da turbidez, Dogliotti et al. (2015) propõem uma abordagem adaptativa. É empregada a banda centrada em 645 nm para águas de baixa turbidez e a banda centrada em 859 nm para águas de alta turbidez. Para as situações intermediárias, os autores introduzem uma transição linear ponderada entre essas duas bandas. Assim, se permite uma estimativa contínua e ajustada às diferentes condições ópticas da água. Esse algoritmo foi desenvolvido originalmente para as bandas do sensor *Moderate-Resolution Imaging Spectroradiometer* (MODIS), a bordo do satélite Aqua. Os autores se basearam em um conjunto de dados contendo 106 amostras *in situ* de turbidez (variando entre 1,8 e 988 FNU) e de reflectância (Equação 2):

$$T = \frac{A_T \rho_w(\lambda)}{1 - \rho_w(\lambda)/C_T} \quad (\text{Eq. 2})$$

onde: A_T para $\rho_w(645 \text{ nm}) = 228,1$ e $\rho_w(859 \text{ nm}) = 3078,9$; C_T para $\rho_w(645 \text{ nm}) = 0,1641$ e $\rho_w(859 \text{ nm}) = 0,2112$.

Para pixels em que $\rho_w(645 \text{ nm}) < 0,05$, é utilizado o algoritmo ajustado para $\rho_w(645 \text{ nm})$. Para aqueles em que $\rho_w(645 \text{ nm}) > 0,07$, o algoritmo utiliza a formulação para $\rho_w(859 \text{ nm})$. Em pixels com valores de $\rho_w(645 \text{ nm})$ entre 0,05 e 0,07, a turbidez é estimada de acordo com a Equação 3:

$$T = (1 - w) \cdot T_{645} + w \cdot T_{859} \quad (\text{Eq. 3})$$

onde: w é a variação linear do peso do algoritmo, que vai de 0 em $\rho_w(645 \text{ nm}) = 0,05$ até 1 em $\rho_w(645 \text{ nm}) = 0,07$; T_{645} é a turbidez calculada usando $\rho_w(645 \text{ nm})$; T_{859} é a turbidez calculada a partir de $\rho_w(859 \text{ nm})$.

Considerando que o sensor MSI não possui bandas exatamente centradas em 645 nm e 859 nm como as do sensor MODIS, foi testada a substituição da banda em 645 nm pela banda em 665 nm e da banda em 859 nm pela banda em 865 nm. A versão adaptada do algoritmo de Dogliotti et al. (2015), com essas substituições, foi denominada D15. Outros algoritmos regionais identificados na literatura (Abdelmalik, 2018; Torres-Bejarano et al., 2021; Wang et al., 2021) não foram considerados neste estudo. Estes foram desenvolvidos para ambientes com características bio-ópticas específicas, distintas das da represa analisada.

Para a seleção do modelo mais acurado na estimativa da turbidez, as variações dos algoritmos de Nechad et al. (2009) e Dogliotti et al. (2015),

com unidade de medida em FNU, foram aplicadas à imagem de 30/06/2022 e comparadas com amostras *in situ*, obtidas em Unidade Nefelométrica de Turbidez (NTU, do inglês *Nephelometric Turbidity Unit*). De acordo com a norma técnica internacional ISO 7027-1 (ISO, 2016), a medida de turbidez em FNU baseia-se na dispersão da radiação infravermelha, detectada a 90° em relação ao feixe incidente.

Por outro lado, a medida de turbidez em NTU baseia-se na detecção da radiação dispersa a 90° em relação ao feixe incidente, no espectro do visível (400-600 nm) (EPA, 1993). Apesar das diferenças metodológicas entre os sistemas de medição em FNU e NTU, relacionadas principalmente ao comprimento de onda utilizado, essas distinções não impedem a comparação entre os valores modelados e *in situ*. Há equivalência numérica entre essas unidades (ISO, 2016).

As amostras *in situ* foram coletadas entre 09:00 e 11:30 na mesma data da imagem Sentinel-

2A, com o apoio e autorização da Companhia de Saneamento de Minas Gerais (COPASA), em 34 pontos distribuídos pela represa. A turbidez foi medida com uma sonda multiparâmetro YSI EXO2 para mensurar a turbidez, entre 15 e 30 cm de profundidade. Os procedimentos para coleta seguem a norma US EPA 180.1 (EPA, 1993). A distribuição espacial dos pontos amostrados é apresentada na Figura 3, enquanto a Figura 4 exibe as estatísticas descritivas dos valores obtidos, expressos em NTU.

Em conformidade com a política de proteção de dados da COPASA, responsável pela gestão da represa, os valores georreferenciados das amostras não podem ser divulgados. É visto, no entanto, que nenhuma das amostras excede 40 NTU. Este é o valor-limite estabelecido para águas de Classe I (COPAM e CERH/MG, 2022), categoria na qual a Represa de Várzea das Flores se enquadra em função de seu uso preponderante (COPAM, 1995).




Figura 3. Localização dos 34 pontos de coleta de dados de turbidez *in situ* no dia 30/06/2022, na Represa de Várzea das Flores, MG, sobrepostos à imagem Sentinel-2A/MSI (cor verdadeira) da mesma data.

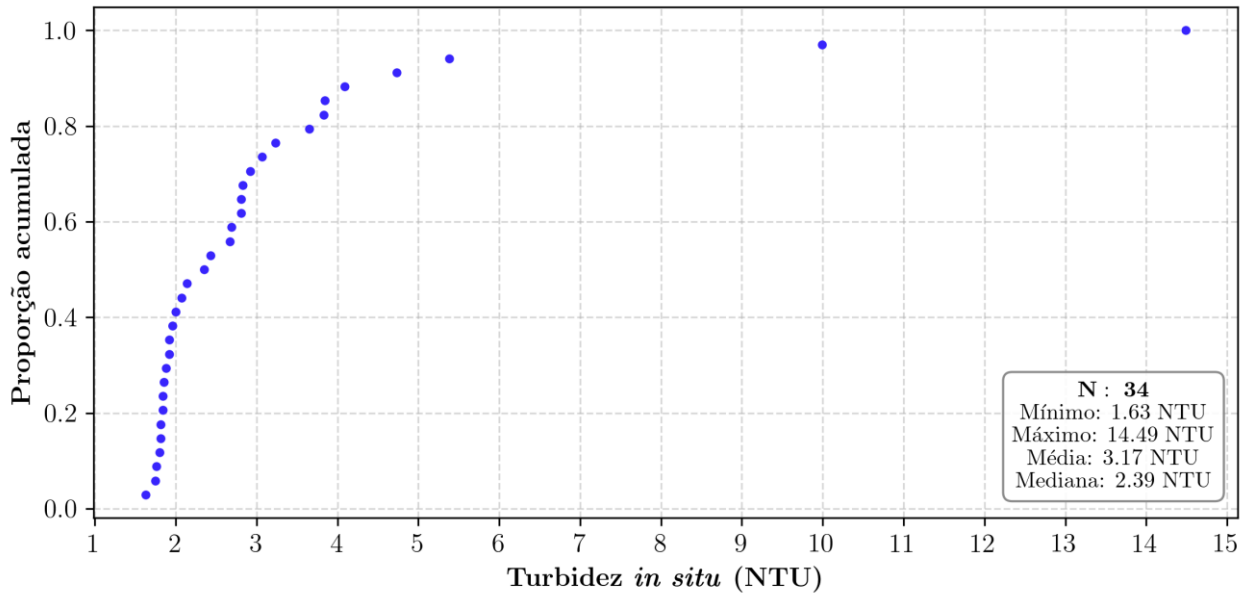


Figura 4. Gráfico da função de distribuição cumulativa empírica dos valores de turbidez (NTU) amostrados *in situ* no dia 30/06/2022, na represa de Várzea das Flores, MG. O gráfico mostra a variabilidade e a frequência acumulada das concentrações de turbidez amostradas, além da descrição estatística de seus valores mínimo, máximo, médio e mediano.

Conforme apresentado por Nguyen et al. (2024), foram utilizadas as seguintes métricas estatísticas para avaliar o desempenho dos modelos: coeficiente de determinação (R^2) (Equação 4), inclinação da reta de regressão (Equação 5), Raiz do Desvio Médio Quadrático (RMSD, do inglês *Root Mean Square Deviation*) (Equação 6), Desvio Percentual Absoluto Médio (MAPD, do inglês *Mean Absolute Percentage Deviation*) (Equação 7), Viés Médio (MB, do inglês *Mean Bias*) (Equação 8) e Razão Mediana (MR, do inglês *Mean Ratio*) (Equação 9).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{Eq. 4})$$

$$\text{Inclinação} = \frac{\text{cov}(\hat{y}_i, y_i)}{\text{var}(y_i)} \quad (\text{Eq. 5})$$

$$\text{RMSD}_{\log} = \sqrt{\frac{\sum_{i=1}^n (\log_{10}(\hat{y}_i) - \log_{10}(y_i))^2}{n}} \quad (\text{Eq. 6})$$

$$\text{MAPD} = \text{mediana} \left(\frac{|\hat{y}_i - y_i|}{y_i} \right) \times 100 \quad (\text{Eq. 7})$$

$$\text{MB} = \text{mediana}(\hat{y}_i - y_i) \quad (\text{Eq. 8})$$

$$\text{MR} = \text{mediana} \left(\frac{\hat{y}_i}{y_i} \right) \quad (\text{Eq. 9})$$

onde: y_i é a turbidez observada; \hat{y}_i a turbidez estimada; \bar{y} é a média das observações; n é o número de observações.

Essas métricas foram normalizadas e utilizadas na construção de polígonos em um gráfico de radar. Nesse tipo de visualização, modelos que apresentam polígonos com a menor área são considerados mais acurados (Tran et al., 2023; Nguyen et al., 2024). As fórmulas correspondentes às métricas estatísticas normalizadas são apresentadas nas Equações 10 a 15, enquanto a Equação 16 descreve o cálculo da área do polígono no gráfico de radar.

$$R^2_{\text{norm}} = \frac{\text{abs}(1 - R^2)}{\max(\text{abs}(1 - R^2))} \quad (\text{Eq. 10})$$

$$\text{Inclinação}_{\text{norm}} = \frac{\text{abs}(1 - \text{Inclinação})}{\max(\text{abs}(1 - \text{Inclinação}))} \quad (\text{Eq. 11})$$

$$\text{RMSD}_{\log}^{\text{norm}} = \frac{\text{RMSD}_{\log}}{\max(\text{RMSD}_{\log})} \quad (\text{Eq. 12})$$

$$\text{MAPD}_{\text{norm}} = \frac{\text{MAPD}}{\max(\text{MAPD})} \quad (\text{Eq. 13})$$

$$\text{MB}_{\text{norm}} = \frac{\text{MB}}{\max(\text{MB})} \quad (\text{Eq. 14})$$

$$\text{MR}_{\text{norm}} = \frac{\text{MR}}{\max(\text{MR})} \quad (\text{Eq. 15})$$

$$\begin{aligned} \text{Área} = & \frac{1}{2} \cdot \text{sen} \frac{\pi}{6} (\text{RMSD}_{\log}^{\text{norm}} \cdot \\ & \text{MAPD}_{\text{norm}} + \text{MAPD}_{\text{norm}} \cdot \text{MB}_{\text{norm}} \\ & + \text{MB}_{\text{norm}} \cdot \text{MR}_{\text{norm}} \\ & + \text{MR}_{\text{norm}} \cdot \text{Inclinação}_{\text{norm}} \\ & + \text{Inclinação}_{\text{norm}} \cdot \text{R}_{\text{norm}}^2 \\ & + \text{R}_{\text{norm}}^2 \cdot \text{RMSD}_{\log}^{\text{norm}}) \end{aligned} \quad (\text{Eq. 16})$$

O modelo mais acurado para a estimativa da turbidez foi aplicado às imagens Sentinel-2 MSI L2A de outras datas, no período entre 2017 e 2024. Os pixels correspondentes a nuvens e sombras de nuvens foram filtrados por meio da máscara *Scene Classification Layer* (SCL). Esta utiliza testes de limiares probabilísticos aplicados à reflectância de topo da atmosfera, razões de bandas e índices espectrais com o objetivo de classificar os pixels nas imagens do sensor MSI (Gascon et al., 2017; Main-Knorn et al., 2017).

As estimativas da temperatura de superfície da água foram derivadas de dados no infravermelho termal da série Landsat. Estas estão disponíveis na plataforma AWS em nível 2, com correção atmosférica por meio do esquema *Land Surface Reflectance Code* (LaSRC). Esses dados, provenientes do sensor *Enhanced Thematic Mapper Plus* (ETM+), embarcado no satélite Landsat 7, e do sensor *Operational Land Imager and Thermal Infrared Sensor* (OLI/TIRS), a bordo dos satélites Landsat 8 e 9. Os mesmos são disponibilizados com resolução espacial reamostrada de 30 metros. A banda termal do ETM+ cobre o intervalo entre 10,4 e 12,50 μm (USGS, 2021), e a banda do OLI, abrange o intervalo entre 10,6 e 11,19 μm (USGS, 2024).

Foram utilizados exclusivamente os pixels correspondentes ao espelho d'água, definidos a partir da aplicação da máscara gerada pelo algoritmo *C Function of Mask* (CFMask) (Foga et al., 2017). Esse algoritmo utiliza limiares aplicados à reflectância, à temperatura de brilho e à banda *cirrus* para classificar os pixels em imagens Landsat, permitindo a separação entre superfícies terrestres e corpos d'água. Considerando que a resolução espacial dos dados de temperatura de superfície difere daquela das imagens Sentinel-2, foi realizado um processo de reamostragem e alinhamento espacial. Assim, se ajustou os pixels das imagens Sentinel-2 para coincidir com a resolução dos dados Landsat.

A temperatura de superfície é um importante indicador das condições ambientais de sistemas aquáticos. Esta é modificada por fatores climáticos, meteorológicos e pelas características de uso e cobertura do solo da bacia hidrográfica

onde esses sistemas estão inseridos (Dokulil et al., 2021; Attiah et al., 2023). Essa variável afeta diretamente processos ecológicos, biológicos e hidrogeoquímicos, como a produtividade e a estratificação da coluna d'água (Dokulil et al., 2021; Attiah et al., 2023).

Outra variável importante para a regionalização é a batimetria. As informações sobre a profundidade são fundamentais para o cálculo do volume de água e para a compreensão de processos hidrológicos e hidrodinâmicos. Estes incluem o transporte de sedimentos e nutrientes, a produtividade primária, a distribuição de organismos e a dinâmica de estratificação da coluna d'água (Yao et al., 2018; Liu e Song, 2022; Martinsen et al., 2023). O levantamento batimétrico em campo fornece dados de alta acurácia, porém, envolve custos elevados, exigindo o uso de ecobatímetros embarcados ou sensores *LiDAR* (Gao, 2009).

Métodos alternativos para estimativa da batimetria têm sido empregados com base em informações da topografia adjacente ao corpo d'água. Assim, se infere a profundidade por meio de diferentes modelos computacionais (Martinsen et al., 2023). Nesse contexto, Khazaei et al. (2022) disponibilizaram um conjunto de dados globais de batimetria de lagos, o *Global Lakes Bathymetry dataset* (GLOBathy). No GLOBathy, a batimetria de mais de 1,4 milhões de corpos d'água foi estimada a partir de um modelo de regressão *Random Forest*. Esse modelo utiliza dados da plataforma HydroLAKES, que fornece informações como área, volume, elevação de superfície e linha de costa dos lagos.

Apresentando resolução espacial de 30 metros, o modelo foi validado com dados de 1.503 corpos d'água, apresentando alto desempenho estatístico: coeficiente de eficiência de Nash-Sutcliffe igual a 0,97, viés percentual de 1,08%, Erro Quadrático Médio de 0,17 e coeficiente de correlação de Spearman de 0,94. Dessa forma, o GLOBathy é um modelo batimétrico que fornece estimativas robustas da profundidade de diferentes ecossistemas aquáticos. Para este estudo, os dados batimétricos da Represa de Várzea das Flores foram obtidos na plataforma *Google Earth Engine* (GEE).

Concluída essa etapa, foi realizado o cálculo da média das variáveis de turbidez e temperatura de superfície para cada pixel, considerando separadamente os períodos de verão (outubro a março) e inverno (abril a setembro) (Santos, 2012). Para esse cálculo, foram usados apenas os valores válidos, ou seja, positivos e

isentos de *outliers*, filtrados com base no intervalo interquartil (Tukey, 1997), descrito na Equação 17:

$$\bar{X}_{\text{pixel}} = \frac{1}{n} \sum_{i=1}^n X_i, \text{ onde:} \quad (\text{Eq. 17})$$

$$X_i \in [Q_1 - 1,5 \times \text{IQR}, Q_3 + 1,5 \times \text{IQR}]$$

\bar{X}_{pixel} é a média dos valores válidos para cada pixel; X_i é o valor do pixel na imagem i ; Q_1 e Q_3 são o primeiro e terceiro quartil dos valores do pixel ao longo do tempo; IQR é o intervalo interquartil; n é o número de imagens com valores válidos.

O dado de batimetria, bem como as médias sazonais de turbidez e de temperatura de superfície da água foram, então, normalizados (Equação 18). Essa etapa é fundamental em técnicas de agrupamento, pois garante que variáveis expressas em diferentes unidades contribuam de forma equilibrada na análise. Assim, são evitadas distorções na formação dos agrupamentos (Han e Du, 2024):

$$X_{\text{normalizada}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (\text{Eq. 18})$$

onde, X é o valor original da variável; X_{\min} é o valor mínimo da variável; X_{\max} é o valor máximo da variável; $X_{\text{normalizada}}$ é a variável normalizada.

As variáveis normalizadas foram utilizadas como dados de entrada no processo de regionalização, por meio dos métodos K-Medoids (Kaufman e Rousseeuw, 1990) e SKATER (Assunção et al., 2006). O método K-médias (*K-means*) agrupa um conjunto de amostras em k agrupamentos (clusters), de modo a minimizar a Soma dos Erros Quadráticos (SSE, do inglês *Sum of Squared Errors*) entre as amostras e o centroide de cada cluster, utilizando a distância euclidiana como métrica de proximidade. Nesse método, o centróide de cada agrupamento é calculado como a média das observações, o que o torna sensível à presença de *outliers* e ruídos nos dados (Entezami et al., 2020).

Como alternativa à sensibilidade do K-médias, Kaufman e Rousseeuw (1990) propuseram o método K-Medoids. Nesse algoritmo de agrupamento, em vez da média, utiliza-se como referência um ponto real do conjunto de dados que esteja mais centralmente localizado, o medoide, para representar cada cluster. Para sua definição, emprega-se uma métrica de proximidade, como as distância Euclidiana, de Manhattan ou de Mahalanobis, a fim de identificar o medoide que minimize a dissimilaridade total em relação aos demais pontos do mesmo agrupamento.

O método *Spatial 'K'cluster Analysis by Tree Edge Removal*, proposto por Assunção et al. (2006), baseia-se na construção e particionamento de uma Árvore Geradora Mínima (AGM), com o objetivo de gerar regiões espacialmente contíguas e internamente homogêneas. Inicialmente, é gerado um grafo de continuidade, no qual cada unidade espacial, representada por geo-objetos (vértices x_i e x_j), corresponde a um nó. Esses nós são interligados por arestas, associadas a um determinado custo (Equação 19), calculado a partir de uma medida de dissimilaridade obtida por uma distância, como a distância Euclidiana (Assunção et al., 2006; Santos e Gonçalves, 2023).

$$\text{Custo}_{i,k} = \sqrt{\sum_{j=1}^m (x_{ij} - x_{kj})^2} \quad (\text{Eq. 19})$$

onde, m é o número de variáveis, i é o nó de referência, k é o nó a ser comparado com i e j é o indexador da variável.

A partir do grafo de continuidade, gera-se a AGM, na qual todos os vértices são conectados sem a formação de ciclos. Prioriza-se sempre as arestas de menor custo para estabelecer as conexões. Com a árvore geradora mínima criada, o algoritmo SKATER executa a remoção iterativa de $k-1$ arestas de maior custo, sendo k o número de regiões desejadas. Essas remoções são realizadas de modo a minimizar a Soma dos Quadrados dos Desvios da Regionalização (SQDR) dentro de cada cluster. Para isso, utiliza-se o cálculo da Soma Total dos Quadrados (SQT), tendo como referência a média global das variáveis analisadas (Equação 20) (Assunção et al., 2006; Santos e Gonçalves, 2023).

$$\text{SQT} = \sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{x}_j)^2 \quad (\text{Eq. 20})$$

Após a remoção de cada aresta, são criadas regiões, e calcula-se, para cada uma, a Soma dos Quadrados dos Desvios em relação à sua média interna (SQR). A soma dos SQRs de todas as regiões compõe a SQDR. O custo associado à remoção de uma aresta é, então, definido pela diferença entre a SQT e a SQDR, representando o ganho em homogeneidade decorrente da remoção daquela aresta. O SKATER seleciona, assim, iterativamente, a remoção da aresta cujo valor de ganho de homogeneidade (SQR - SQDR) seja maximizado. Isto é feito até que se atinja o número desejado de regiões (Assunção et al., 2006; Santos e Gonçalves, 2023).

Utilizou-se a distância Euclidiana como métrica de dissimilaridade para a regionalização em ambos os modelos, conforme apresentado na Equação 21:

$$D_{i,j} = \sqrt{(x_i - x_j)^T (x_i - x_j)} \quad (\text{Eq. 21})$$

onde $D_{i,j}$ é a distância euclidiana entre dois vetores x_i e x_j de s dimensões. Um modelo conceitual para ilustração dos processos de regionalização pelo algoritmo K-Medoids e SKATER é apresentado na Figura 5. Neste, o centroide de cada pixel da grade vetorial das variáveis normalizadas é considerado um geo-objeto.

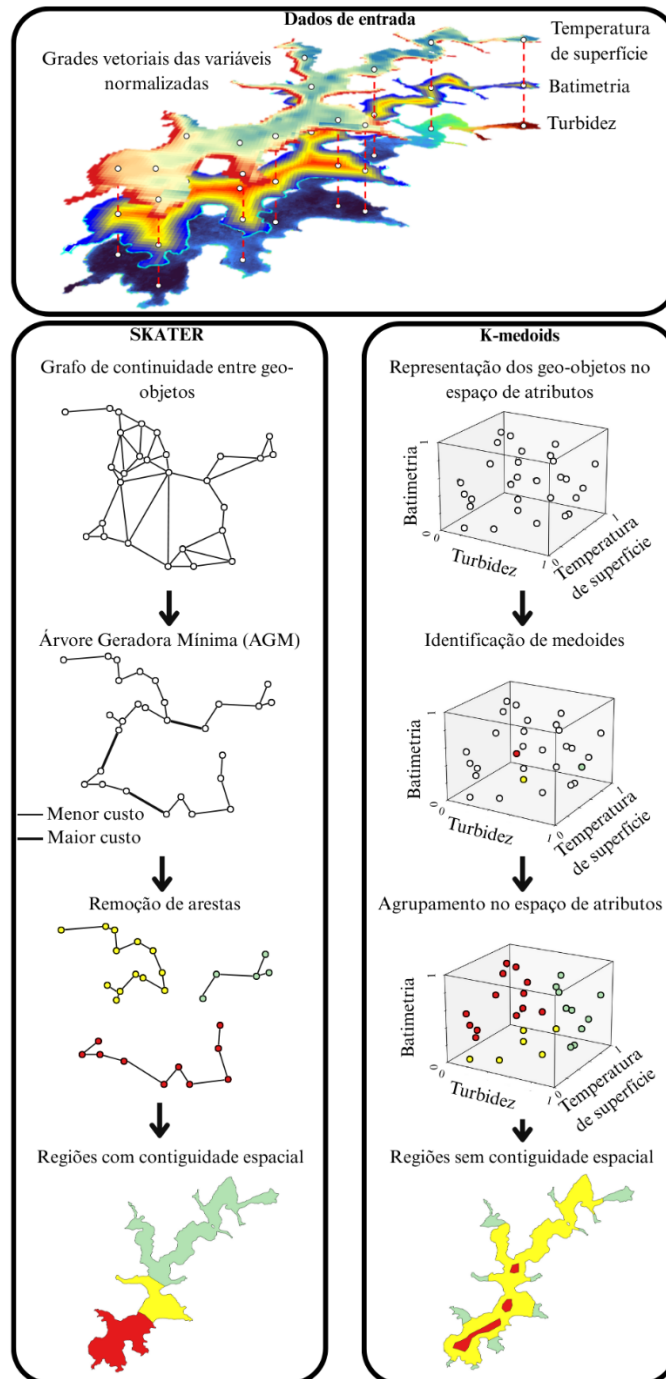


Figura 5. Modelo conceitual para ilustração do processo de regionalização da represa de Várzea das Flores, MG, pelos algoritmos K-Medoids e *Spatial 'K'cluster Analysis by Tree Edge Removal*. O modelo apresenta de maneira abstrata o processo de regionalização para alguns geo-objetos (centróides das variáveis normalizadas), demonstrando como os algoritmos agrupam informações espaciais similares.

Foram aplicados os métodos *Elbow* (Thorndike, 1953) e *Silhouette Score* (Rousseeuw, 1987). Estes serviram para definir qual o número ideal de regiões no espelho d'água, tanto para o verão quanto para o inverno, em cada um dos dois métodos de regionalização considerados. O método *Elbow* baseia-se na análise gráfica da SSE intra-cluster (Equação 22). Se verifica a sua diminuição, à medida em que se aumenta o número de agrupamentos (k), até o ponto em que esse aumento deixa de representar uma redução significativa no SSE. Esse ponto, que assume a forma visual de um “cotovelo” no gráfico, indica o número ótimo de clusters (Thorndike, 1953).

$$SSE = \sum_{r=1}^k \sum_{c(i)=k} \sqrt{(x_i - c_k)^T (x_i - c_k)^T} \quad (\text{Eq. 22})$$

onde, k é o número de clusters; c_k é o centroide do cluster k ; $\sum_{r=1}^k$ é o somatório externo que abrange todos os clusters; $\sum_{c(i)=k}$ é o somatório interno que considera apenas os pontos pertencentes ao cluster k .

O *Silhouette Score* (Rousseeuw, 1987), por sua vez, é um coeficiente que varia de -1 a 1. Este é utilizado para avaliar a adequação da alocação de uma observação em seu respectivo cluster. Valores próximos a 1 indicam que a observação está bem separada dos demais agrupamentos. Coeficientes próximos de 0 indicam que a observação se encontra na fronteira entre dois clusters. Valores próximos a -1 sugerem possível alocação incorreta da observação (Rousseeuw, 1987). A Equação 23 apresenta a fórmula utilizada para o cálculo do *Silhouette Score*:

$$s = \frac{b-a}{\max(a,b)} \quad (\text{Eq. 23})$$

onde, s é o *Silhouette Score*; a é a coesão do cluster, dada pela distância média de cada observação para os pontos do mesmo cluster; b é a separação do cluster em relação aos outros, calculada pela distância média entre a observação e todas as observações do cluster distinto mais próximo.

O método *Elbow* e *Silhouette Score* também foram utilizados para definir o modelo de regionalização mais adequado. Considerou aquele que apresenta uma queda mais acentuada na SSE, evidenciando o ponto de inflexão característico do método *Elbow*, aliada ao maior valor do *Silhouette Score*. Com base no modelo de regionalização considerado mais acurado e no número ótimo de clusters, foi realizada uma análise qualitativa das regiões criadas. Esta se baseou na literatura descritiva dos principais tributários da represa e

dos valores médios, mínimos e máximos das variáveis consideradas.

Por fim, realizou-se uma Análise de Variância Multivariada (MANOVA) (O'Brien e Kaiser, 1985). Ela foi utilizada para comparar as regionalizações obtidas para o verão e o inverno. A MANOVA permite verificar se há diferenças estatisticamente significativas entre variáveis dependentes (temperatura de superfície, turbidez e batimetria) em função de um fator categórico, como as estações do ano (O'Brien e Kaiser, 1985; Stähle e Wold, 1990). Trata-se de uma técnica amplamente utilizada para quantificar diferenças entre grupos (Huang et al., 2020). A análise compara a variação total explicada entre os grupos (matriz B) e a variação interna dentro de cada grupo (matriz W), por meio da razão $B \cdot W^{-1}$, que permite mensurar a separabilidade entre os grupos.

Para a avaliação da MANOVA, foram aplicados os testes estatísticos *Wilk's Lambda*, *Pillai's Trace*, *Hotelling-Lawley Trace* e *Roy's Greatest Root*. Testou-se a hipótese nula (H_0) de que os vetores das médias multivariadas de turbidez, temperatura de superfície e batimetria são iguais nas regionalizações do inverno e do verão. Em síntese, cada um desses testes avalia a significância estatística das diferenças entre as regionalizações, sendo sensível, em graus distintos, a possíveis violações dos pressupostos da MANOVA. Estas incluem a normalidade multivariada, homogeneidade das matrizes de covariância e independência das observações (Stähle e Wold, 1990; Ateş et al., 2019).

A significância estatística foi avaliada por meio da transformação de cada estatística multivariada em valores F. Isto possibilitou a obtenção dos respectivos p-valores. Dessa forma, considerou-se a hipótese nula não rejeitada quando o p-valor foi superior a 0,05, adotando-se um nível de significância de 95%. Para um aprofundamento conceitual sobre a MANOVA e os testes estatísticos empregados, recomenda-se a leitura de O'Brien e Kaiser (1985), Stähle e Wold (1990), Ateş et al. (2019) e Huang et al. (2020).

Resultados e discussão

Seleção do algoritmo mais acurado para estimativa da turbidez

A Figura 6 apresenta os gráficos de ajuste dos algoritmos de Dogliotti et al. (2015) e Nechad et al. (2009) em relação os dados *in situ*. A Figura 7 exhibe o gráfico de radar gerado a partir das métricas estatísticas de desempenho normalizadas. A análise do algoritmo de Dogliotti et al. (2015)

indica que a substituição das bandas originais por bandas do sensor MSI Sentinel-2, 665 nm no lugar de 645 nm, e 865 nm no lugar de 859 nm, é válida para a estimativa de turbidez na represa (Figura 6a). Estudos prévios já demonstraram a aplicabilidade desse algoritmo adaptado às bandas do MSI em diferentes sistemas aquáticos, com resultados satisfatórios (Kuhn et al., 2019; Sent et al., 2021; Warren et al., 2021).

Ao analisar as diferentes variações do algoritmo de Nechad et al. (2009), observa-se um aumento contínuo da área no gráfico de radar (Figura 7). Isso acontece à medida que são

utilizadas bandas com comprimentos de onda superiores a 665 nm para a estimativa da turbidez, o que indica uma redução no desempenho. Tal comportamento mostra que a reflectância em bandas de menor comprimento de onda é mais sensível a condições de baixa turbidez (Nechad et al., 2010; Dogliotti et al., 2015), como as observadas nas amostras com valores inferiores a 15 (NTU). Dessa forma, os algoritmos com melhor desempenho para estimativa da turbidez foram o de Dogliotti et al. (2015) e a versão do algoritmo de Nechad et al. (2009) utilizando a banda centrada em 665 nm.

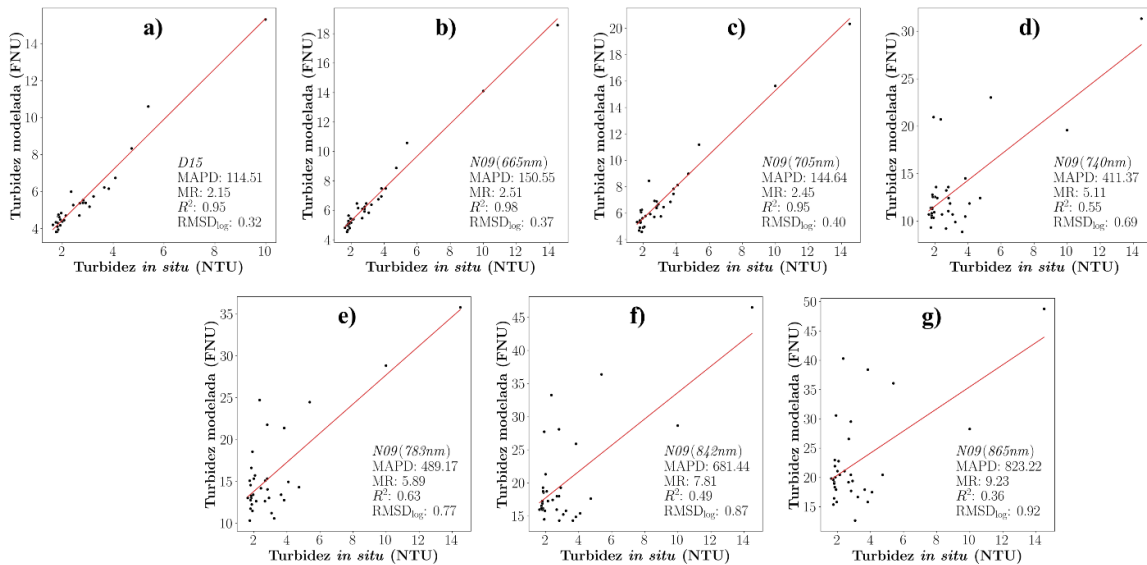


Figura 6. Gráficos de ajuste dos algoritmos para estimativa de turbidez em relação aos dados *in situ*, coletados em 30/06/2022, na Represa de Várzea das Flores, MG. No eixo x, estão os valores de turbidez *in situ* (NTU), enquanto no eixo y estão os valores da turbidez derivada dos seguintes modelos para estimativa de turbidez (FNU) por dados de sensoriamento remoto: (a) Algoritmo de Dogliotti et al. (2015) adaptado para as bandas MSI em 665 nm e 842 nm; (b-g) Variações do modelo de Nechad et al. (2009), aplicadas às bandas em 665 nm (b), 705 nm (c), 740 nm (d), 783 nm (e), 842 nm (f) e 865 nm (g).

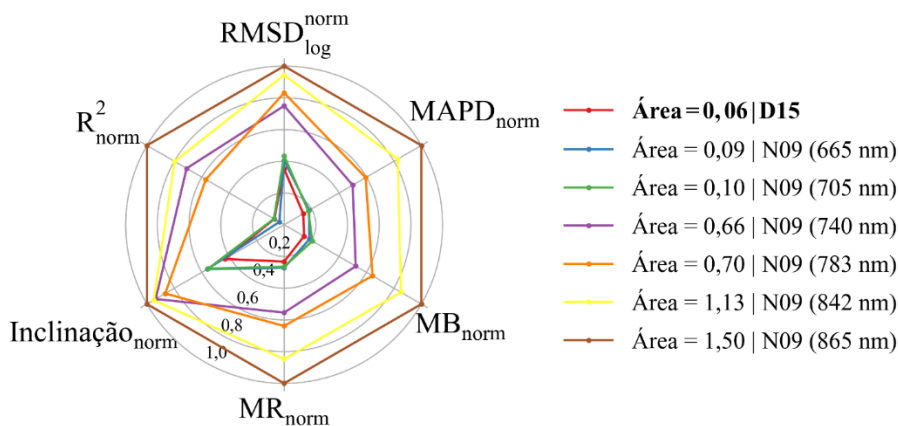


Figura 7. Gráfico de radar sintetizando o desempenho dos diferentes algoritmos para estimativa de turbidez a partir da imagem MSI Sentinel-2A de 30/06/2022, na Represa de Várzea das Flores, MG. Quanto menor a área do polígono associado a um modelo, melhor seu desempenho segundo as métricas estatísticas normalizadas.

O algoritmo de Dogliotti et al. (2015), no entanto, apresentou desempenho superior, conforme evidenciado por sua menor área no gráfico de radar. Em razão disso, foi selecionado para aplicação nas 666 imagens disponíveis, entre janeiro de 2017 e dezembro de 2024, referentes à área de estudo. Esse desempenho pode ser atribuído à sua calibração em um conjunto mais amplo e diversificado de ambientes bio-ópticos, incluindo cinco sistemas aquáticos com concentrações de turbidez variando entre 1 e 988 FNU, a partir de 106 amostras. Já o algoritmo de Nechad et al. (2009) foi desenvolvido com um conjunto menor de amostras (N = 45), coletadas no Mar do Norte Meridional, abrangendo uma faixa mais restrita de turbidez, entre 0,59 e 83,63 FNU.

A abordagem para estimativa de turbidez, com base no algoritmo semianalítico de Dogliotti et al. (2015) aplicado às imagens MSI Sentinel-2, representa uma inovação no uso de sensores orbitais para o monitoramento qualitativo da Represa de Várzea das Flores. Contudo, esforços adicionais são necessários para que o modelo consiga representar uma gama mais ampla de valores de turbidez e diferentes composições bio-ópticas do corpo d'água. Assim, é recomendável que sejam feitas validações futuras, a partir de amostras coletadas em outras datas. Essa ampliação contribuirá para melhorar a capacidade de generalização e o desempenho do modelo em diferentes condições ambientais.

Temperatura de superfície água e batimetria da represa de Várzea das Flores

Entre janeiro de 2017 e dezembro de 2024, foram identificadas 124 imagens de temperatura de superfície da água. Por se tratar de um número relativamente inferior ao conjunto de mais de 650 imagens com dados de turbidez, é fundamental considerar as limitações associadas à análise temporal dessa variável. Assim, há a necessidade de complementação com outras fontes de dados em estudos futuros, no sentido de reduzir a influência do número reduzido de imagens às estimativas de temperatura.

Apesar da limitação em termos de frequência temporal, sensores termais ainda representam a melhor alternativa para a obtenção de dados de temperatura da superfície da água em áreas com grande extensão espacial (Li et al., 2023). Sensores com maior frequência de revisita, como o MODIS, não oferecem resolução espacial compatível com as dimensões da represa analisada, inviabilizando sua aplicação neste caso. Por esse motivo, optou-se pela utilização das imagens provenientes da série Landsat que, embora menos frequentes, apresentam resolução espacial adequada. A Figura 8 exemplifica a estimativa da temperatura de superfície da água na represa de Várzea das Flores, a partir desses dados.

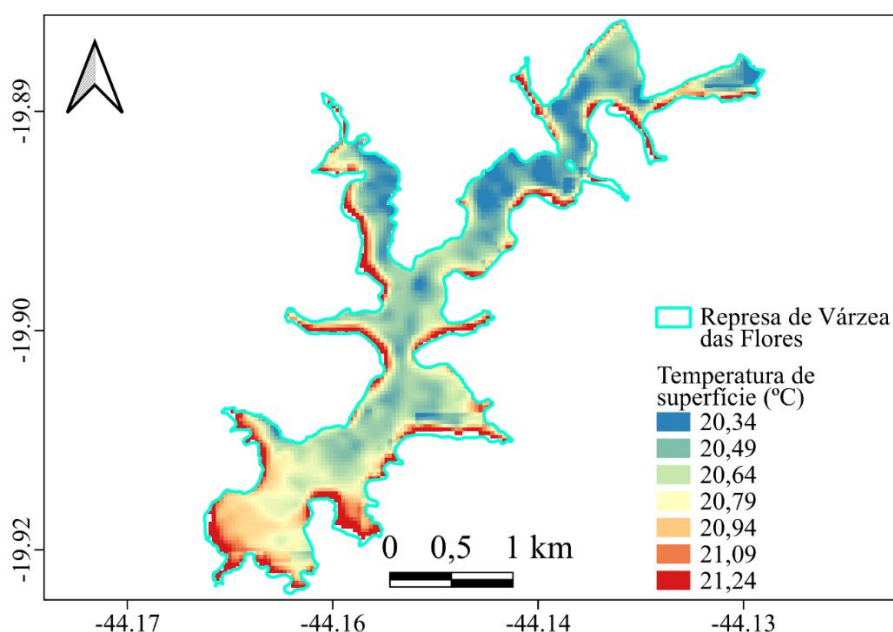


Figura 8. Mapa de temperatura de superfície da água na represa de Várzea das Flores, estimada a partir da imagem do dia 23/06/2022, obtida pelo sensor termal *Operational Land Imager and the Thermal Infrared Sensor*, a bordo do satélite Landsat-8. A variável de temperatura de superfície da água é utilizada no processo de regionalização proposto.

A represa apresentou profundidades variando entre 2,5 e 28,3 metros, de acordo com o modelo GLOBathy (Khazaei et al., 2022). Esses valores diferem dos reportados por Santos (2012). O autor realizou um levantamento ecobatimétrico com 18.330 sondagens em 2009, no qual as profundidades variavam de 0 a 22 metros, em relação à cota de altitude de 837,37 metros. Nesse contexto, a batimetria estimada pelo GLOBathy

(Figura 9) deve ser compreendida como uma aproximação da profundidade real da represa. Assim, é recomendável a realização de um novo levantamento batimétrico para representar com maior acurácia a topografia de fundo do corpo d'água. Essa é, no entanto, uma informação pública, acompanhada de métricas robustas de validação global, conforme apresentado na seção de Procedimentos metodológicos.

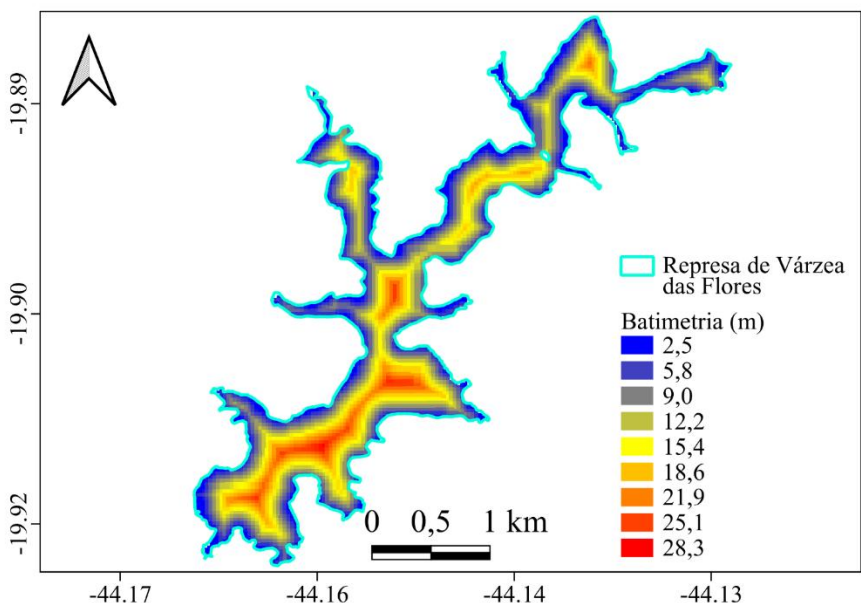


Figura 9. Mapa batimétrico de profundidade modelada em metros da represa de Várzea das Flores, MG. Esses dados são derivados do conjunto estimativo de dados *Global Lakes Bathymetry dataset* (Khazaei et al., 2022), sendo utilizados com uma das variáveis para delimitação das regiões na represa.

Média sazonal e normalização das variáveis

Para o cálculo das médias sazonais de turbidez, foram utilizadas 486 imagens Sentinel-2 para o inverno (estação seca) e 180 para o verão (estação chuvosa). No caso da temperatura de superfície da água, foram consideradas 86 imagens válidas para o inverno e 38 para o verão. A Figura 10 apresenta os valores das médias sazonais dessas duas variáveis.

Os valores de turbidez variaram entre 4,13 e 14,7 NTU no inverno, e entre 4,72 e 29,15 NTU no verão. Já a temperatura da superfície da água apresentou variação de 22,74 e 30,02 °C no inverno, e de 27,37 a 31,68°C no verão. Um exemplo do processo de normalização aplicado a essas duas variáveis, em conjunto com a batimetria, é apresentado na Figura 11.

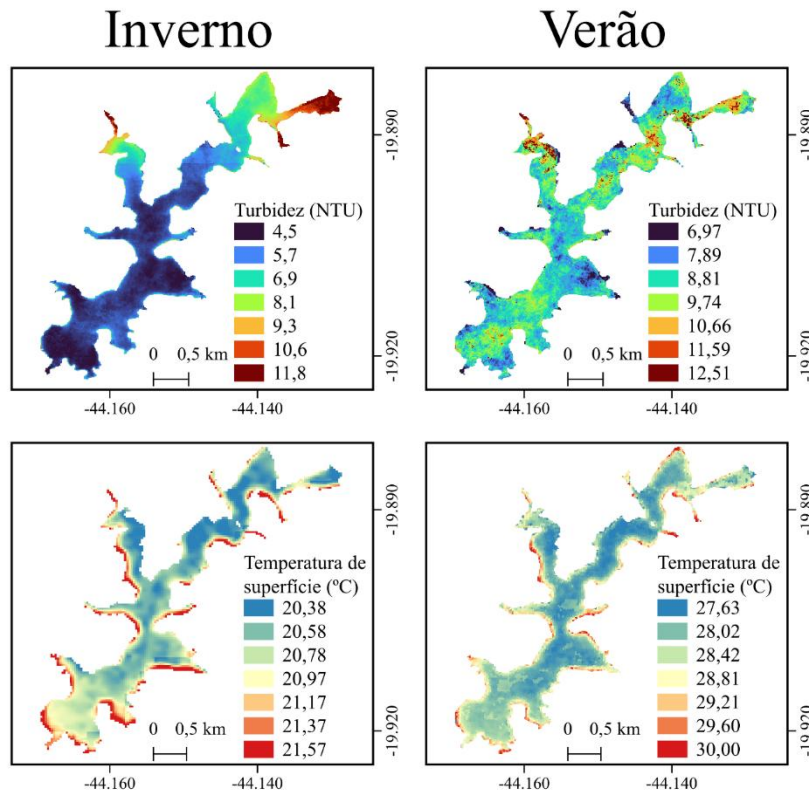


Figura 10. Mapas dos valores médios sazonais de turbidez e temperatura da superfície da água na represa de Várzea das Flores, entre os anos de 2017 e 2024. Esses dados foram derivados de imagens dos sensores a bordo dos satélites Sentinel-2 (turbidez) e Landsat (temperatura), para as estações de inverno (seca) e verão (chuvosa).

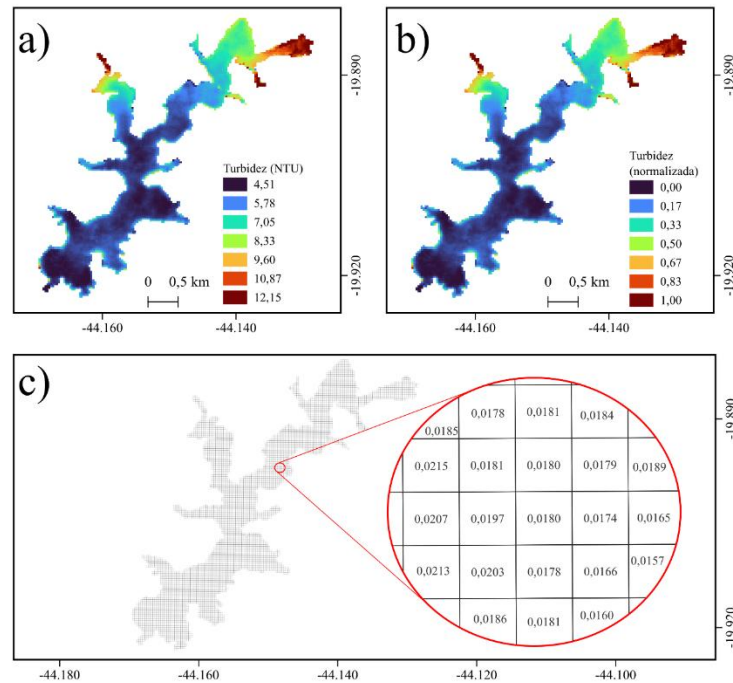


Figura 11. Mapa de exemplo do processo de normalização da média sazonal de turbidez do inverno (2017-2024), na represa de Várzea das Flores. É ilustrada a transformação dos valores absolutos de turbidez (NTU) (a) para valores normalizados (0 a 1). Na parte inferior (c), é apresentada a grade em formato vetorial, onde cada célula apresenta um valor normalizado.

Regionalizações

A Figura 12 apresenta os gráficos da Soma dos Erros Quadráticos e do *Silhouette Score* para as regionalizações com diferentes números de *clusters*. Observa-se, inicialmente, que o SSE é

consistentemente menor e o *Silhouette Score* maior nas regionalizações obtidas pelo método K-Medoids (Figura 12a,b), considerando-se o mesmo número de *clusters* e a mesma estação do ano.

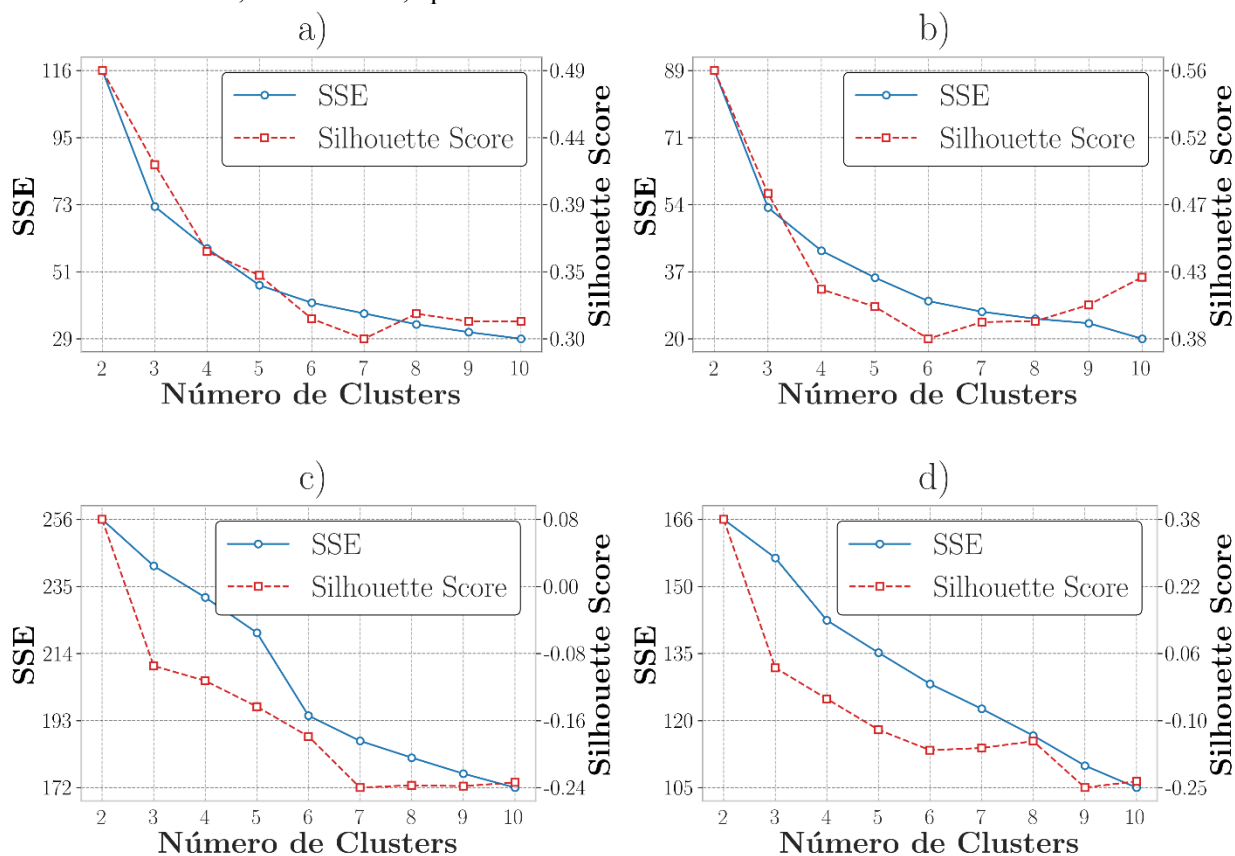


Figura 12. Definição do número ótimo de regiões. Os gráficos apresentam as métricas de Soma dos Erros Quadráticos e do *Silhouette Score* em função do número de regiões para: regionalização no verão (a) e no inverno (b), pelo método K-Medoids; regionalização no verão (c) e no inverno (d), pelo método SKATER. O ponto em que há um “cotovelo” na curva de SSE em conjunto a um pico no *Silhouette Score* indica o número ótimo de regiões por método e estação.

Assim, é possível afirmar que o método K-Medoids forma grupos com maior homogeneidade interna. Esses resultados indicam, também, que o mesmo grupo não necessariamente deve apresentar contiguidade espacial. Esta é uma restrição do método SKATER (Assunção et al., 2006), o que o torna menos aplicável ao contexto da represa de Várzea das Flores.

O ponto de inflexão identificado pelo método *Elbow* para a regionalização via K-

Medoids, ou seja, a queda mais acentuada no SSE, ocorre quando o número de clusters é igual a 3, tanto para o inverno quanto para o verão. Esse número de *clusters* representa um equilíbrio com os valores do *Silhouette Score*, que são 0,47 para o inverno e 0,42 para o verão. Com base nesse resultado, foram geradas as regiões para o inverno pelo método K-Medoids, conforme apresentado na Figura 13.



Figura 13. Mapa das regiões homogêneas (*clusters*) para o período de inverno (seco), gerado pelo algoritmo K-Medoids com 3 *clusters*. Cada região representa uma área com características similares de turbidez, temperatura e batimetria, durante o inverno.

A região denominada “Margem” é caracterizada por menores profundidades, variando entre 2,53 e 8,01 metros, além de concentrar os maiores valores de turbidez (6,67 – 14,7 NTU). Esta área também apresenta elevada amplitude térmica, com temperaturas de superfície variando entre 23,3 e 30,02 °C. A concentração dos maiores níveis de turbidez nessa região reflete a influência dos principais afluentes da represa (Córrego Bela Vista, Ribeirão Betim e Córrego Água Suja) que escoam diretamente para esse setor.

São esses tributários que recebem a maior carga de nutrientes, efluentes, matéria orgânica e partículas provenientes do esgotamento sanitário deficitário, da urbanização, de atividades de mineração e do descarte de resíduos sólidos (Magalhães Júnior et al., 2016; Santos et al., 2018). Nessa região, é recomendável concentrar as coletas de parâmetros de qualidade da água, visando compreender as variações na turbidez em resposta às pressões antrópicas na bacia hidrográfica.

Outra região de destaque, definida pelo K-Medoids no inverno, é a região “Central”. Ela apresenta as maiores profundidades, variando entre 14,77 e 27,27 metros, além dos menores valores médios de turbidez (5,12 a 7,78 NTU). A região Central também apresenta a menor amplitude térmica, com temperaturas de superfície entre 22,74 e 23,52 °C.

Em contraste com a margem, esta é a região com menor influência dos escoamentos provenientes dos afluentes da represa, apresentando menor amplitude térmica e os mais baixos valores de turbidez. A coleta de dados limnológicos nessa área é de grande importância, uma vez que aumentos significativos de temperatura e turbidez podem indicar impactos mais severos decorrentes de alterações na bacia hidrográfica.

A região de “Transição”, por sua vez, funciona como uma zona intermediária entre as demais, caracterizando-se como área de mistura. À

medida que aumentam a profundidade e a distância em relação às desembocaduras dos afluentes, observa-se uma tendência de redução da

instabilidade térmica e dos valores de turbidez. A Figura 14 apresenta as regiões da represa na estação chuvosa.

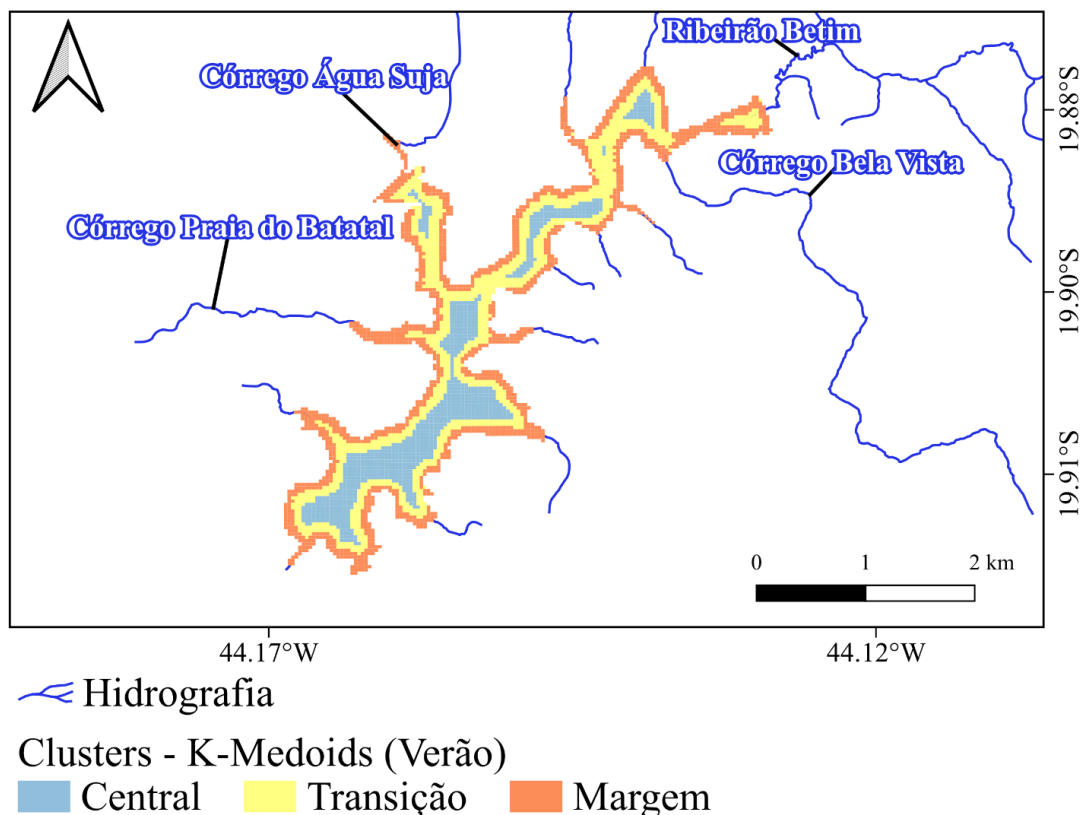


Figura 14. Mapa das regiões homogêneas (clusters) para o período de verão (chuvoso), gerado pelo algoritmo K-Medoids com 3 clusters. Cada região representa uma área com características similares de turbidez, temperatura e batimetria, durante o verão. A comparação desta figura com a Figura 13, de regiões do inverno, permite verificar a existência de padrões espaciais semelhantes em ambas estações.

O método K-Medoids forneceu regiões com padrões semelhantes também no período chuvoso. A região “Margem”, caracterizada pelas menores profundidades (2,53 a 10,13 metros), apresentou os maiores valores de turbidez (0,92 a 29,15 NTU). Apresentou também a menor temperatura mínima (28,78°C) e máxima (31,68°C), sendo, portanto, a região com maior variação térmica. Esse comportamento pode estar relacionado ao aumento do volume de água próximo aos exultórios durante o período chuvoso, elevando a turbidez nas áreas menos profundas em função do aporte de nutrientes (Verdonschot et al., 2013; Taylor e Rising, 2021).

A amplitude térmica, por sua vez, pode ser potencialmente explicada pela mistura d’água com diferentes temperaturas, oriundas do escoamento a montante da represa. No entanto, investigações

adicionais são necessárias para confirmar se essa dinâmica está de fato relacionada a esses fatores. De maneira semelhante à regionalização obtida pelo K-Medoids no inverno, a zona “Central” no verão corresponde à área com as maiores profundidades (14,32 – 27,27 m). Esta também é a área de menor amplitude térmica, com temperaturas de superfície variando entre 27,37 e 28,72 °C.

Com baixos valores de turbidez (7,07 – 13,52 NTU), essa região continua sendo estratégica para compreender possíveis impactos mais intensos decorrentes de mudanças na bacia hidrográfica. Assim como observado no período seco, a região de “Transição” funciona como uma zona intermediária entre a “Margem” e a região “Central” da represa.

Há, dessa forma, uma gradual transição entre áreas rasas, caracterizadas por maior amplitude térmica e maior turbidez, e áreas mais profundas, com menor amplitude térmica e menor turbidez. Um dos fatores que explica a maior concentração de turbidez nessa dinâmica é a diminuição progressiva da influência direta do aporte de materiais pelos afluentes, em função de sua dispersão ao longo do reservatório, conforme observado em outros sistemas (Powers et al., 2023). Conforme o contexto supramencionado, esses afluentes são diretamente afetados pelas atividades antropogênicas desenvolvidas na represa. Assim, atuam como vetores de sedimentos. A precipitação intensifica esse processo ao promover a geração do escoamento superficial, a erosão do solo e o transporte a jusante dos sedimentos mobilizados (Armijos et al., 2020; Cisty et al., 2021).

Outros fatores, no entanto, também emergem como determinantes das diferenças biogeoquímicas observadas entre as regiões. Isso se deve principalmente às interações entre as variáveis utilizadas para regionalização. A profundidade atua como um fator determinante da inércia térmica, ao passo em que áreas de menor profundidade apresentam menor capacidade de armazenamento de calor (Amadori et al., 2024; Zhang et al., 2024). Por essa razão, as áreas mais rasas respondem mais facilmente às variações climáticas, contrastando com porções mais profundas, em que a persistência térmica garante uma menor amplitude sazonal dos valores de temperatura (Amadori et al., 2024; Zhang et al., 2024). No contexto da represa, esses dois padrões se contrastam entre as regiões “Margem” e “Central”, com a região intermediária funcionando como área de transição.

A turbidez também afeta a temperatura superficial, ao controlar a absorção e a redistribuição da radiação solar na coluna d’água. Sistemas aquáticos com maior turbidez tendem a concentrar na camada superficial a energia solar, o que resulta em um aquecimento mais rápido e uma maior amplitude térmica. Em contraste, sistemas mais transparentes permitem uma maior penetração e distribuição vertical do calor, favorecendo uma maior estabilidade térmica (Nitishi e Indu, 2025).

Adicionalmente, áreas rasas são mais facilmente afetadas pela ação hidrodinâmica do vento, capaz de ressuspender sedimentos e

diminuir a transparência da coluna d’água (Cartwright et al., 2021; Coccia et al., 2024). Assim, diferentes fatores influenciam diretamente a temperatura de superfície e a turbidez ao longo do gradiente de profundidade, de modo que profundidade, temperatura e turbidez interagem de forma interconectada. As três regiões identificadas refletem essa dinâmica.

Regiões semelhantes foram encontradas por outros autores em diferentes reservatórios e lagoas. Evans et al. (2025) utilizou o algoritmo K-médias para definir regiões no lago Darlings, no Canadá, a partir de índices espectrais derivados de imagens multiespectrais de alta resolução espacial PlanetScope. O intuito dos autores foi identificar e classificar áreas de acordo com a intensidade de florações de cianobactérias. Foram identificadas 6 regiões com forte similaridade com as identificadas na represa de Várzea das Flores.

Em regiões marginais de menor profundidade, foram identificadas classes com maiores valores do índice *Normalized Difference Chlorophyll Index* (NDCI), associado à biomassa algal. De modo semelhante ao que foi encontrado na região “Margem” da represa de Várzea das Flores, essa área recebe um maior aporte fluvial de uma bacia hidrográfica antropizada, com presença de atividades agrícolas. Áreas de maior profundidade, por sua vez, apresentaram menor NDCI. Isso reflete a menor influência dos tributários e menor disponibilidade de nutrientes, em uma dinâmica semelhante à região “Central” encontrada na represa, com menores valores de turbidez.

Kim et al. (2025) analisaram 24 anos de dados de concentração de clorofila-a (Chl-a) no lago Erie, entre Estados Unidos e Canadá. Essas informações eram provenientes do sensor orbital MODIS-Terra e foram utilizadas para classificar o nível trófico e identificar, por cada um destes, tendência de aumento da Chl-a. As áreas eutróficas próximas à margem apresentaram uma maior tendência de aumento, seguidas pelas zonas de transição mesotróficas, enquanto a região oligotrófica apresentou a menor tendência. Esse lago recebe influências de aportes de nutrientes de uma bacia hidrográfica majoritariamente antropizada, em que 60,21% de sua área é coberta pelo uso e ocupação do solo urbano e 18,4% por agricultura. Novamente, a influência maior de ações antrópicas na variável analisada aparece na

margem, sendo progressivamente maior na região central do sistema aquático.

Para avaliar a poluição por arsênio, Matsui e Kageyama (2022) utilizaram informações ópticas multiespectrais ALOS AVNIR-2 em conjunto com dados batimétricos, regionalizando o lago Hosenko, no Japão. Nesse sentido, o método de agrupamento *fuzzy c-mean* foi empregado para associar a reflectância nas faixas espectrais do visível e infravermelho próximo ao hidróxido férrico hidratado, principal indicador de contaminação por arsênio. Foram identificadas 2 regiões, posteriormente refinadas pela aplicação de uma rede neural que integrou a profundidade do lago. Observou-se, assim, que a região de menor profundidade era a mais poluída, enquanto a de maior profundidade era menos poluída. Segundo os autores, essa dinâmica evidenciou que a distribuição espacial da poluição é modulada pela batimetria e estratificação, de maneira gradual em termos longitudinais e verticais.

Outros autores reportaram conclusões semelhantes, de acordo com as diferentes variáveis e métodos de agrupamento utilizados para a regionalização. Meng et al. (2024) utilizaram 21 variáveis de qualidade da água medidas *in situ*, incluindo Chl-*a*, turbidez, nitrogênio e fósforo, integradas a imagens Sentinel-2 e redes neurais convolucionais. Isso permitiu particionar o Lago Dianchi, na China, em quatro regiões limnológicas, separando áreas rasas altamente eutrofizadas de regiões mais profundas e menos eutrofizadas.

Wang et al. (2024), por sua vez, regionalizaram o Lago Daihai a partir de dados de reflectância do sensor MSI do satélite Sentinel-2 utilizando *fuzzy c-means*. Os autores identificaram

três classes ópticas associadas a variações espaciais de sólidos em suspensão, fitoplâncton e profundidade. Foram diferenciadas regiões marginais turvas, de transição e uma central, menos influenciada por um contexto de crescente deterioração da qualidade da água por atividades antrópicas.

Assim, a represa de Várzea das Flores insere-se em um padrão recorrente observado em outros sistema lênticos sujeitos a pressões antrópicas. A regionalização responde de forma consistente à interação entre ecossistema aquático, o contexto da bacia hidrográfica e aos fatores que influenciam as variáveis selecionadas.

MANOVA

Os resultados da Análise de Variância Multivariada, realizada com base nas regionalizações com 3 clusters para o inverno e o verão, são apresentados na Tabela 2. Observa-se uma diferença estatisticamente significativa entre as regionalizações das estações seca e chuvosa, com valor de $p < 0,05$ em todos os testes estatísticos aplicados.

Dessa forma, rejeita-se a hipótese nula de que os vetores das médias multivariadas de turbidez, temperatura de superfície da água e batimetria são iguais entre as regionalizações do inverno e do verão. Isso indica que o método K-Medoids demonstrou robustez estatística na regionalização da represa de Várzea das Flores, considerando as variações sazonais e as variáveis analisadas. Outros testes, como modelos de curva de crescimento ou análises multiníveis, podem ser aplicados com o objetivo de avaliar mudanças temporais nas regiões identificadas (Huang et al., 2020).

Tabela 2 – Resultados da Análise de Variância Multivariada para comparação entre as regionalizações da represa de Várzea das Flores obtidas pela aplicação do método K-Medoids no inverno e no verão, com base nas variáveis turbidez, temperatura da superfície da água e batimetria. Todos os testes apresentaram significância estatística ($p < 0,05$), confirmando diferença estatisticamente significativas entre as duas regionalizações.

Medida	Valor	F-valor	p-valor
Wilks' lambda	0,0015	458,3	0,0022
Pillai's trace	0,9985	458,3	0,0022
Hotelling-Lawley trace	687,4	229,16	0,0485
Roy's greatest root	687,4	458,3	0,002

Conclusões

A represa de Várzea das Flores possui importância vital para o abastecimento hídrico da Região Metropolitana de Belo Horizonte. Compreender a dinâmica espacial da distribuição de parâmetros de qualidade da água é essencial para sua caracterização fornecendo subsídios relevantes para ações de conservação, especialmente para os agentes responsáveis pela sua gestão ambiental.

Métodos apropriados para essa finalidade podem ser baseados em modelagem estatística espacial e no uso de dados geoespaciais, com destaque para o sensoriamento remoto. A metodologia adotada neste estudo indicou que o algoritmo semianalítico de Dogliotti et al. (2015) é o mais adequado para a estimativa da turbidez na represa. Este método pode ser aplicado em outros estudos com objetivos distintos. No entanto, é importante ampliar a validação do algoritmo, com maior esforço amostral em outros pontos da represa e estações do ano. Pode-se incluir também variáveis bio-ópticas complementares.

O método K-Medoids, com três regiões, mostrou-se o mais indicado para a regionalização do espelho d'água da represa, quando comparado ao método SKATER. Em futuros trabalhos, poderão ser incorporadas outras variáveis no processo de regionalização. Estas incluem pH, fósforo e nitrogênio, bem como dados de batimetria obtidos por ecobatímetro ou *LiDAR*.

As regiões homogêneas definidas pelo K-Medoids também revelam diferentes dinâmicas no interior da represa. As áreas marginais, especialmente próximas aos exutórios dos principais afluentes, respondem de forma mais acentuada às atividades que degradam os recursos hídricos, tanto no inverno quanto no verão. Já a região central, caracterizada por maior profundidade, menor amplitude térmica e menores valores de turbidez, pode funcionar como uma área de referência para o monitoramento. Alterações significativas em seus parâmetros podem indicar impactos mais severos decorrentes de mudanças na bacia hidrográfica.

Por fim, a análise MANOVA indicou diferenças estatisticamente significativas entre as regionalizações realizadas para o inverno e para o verão. Isto reforça a robustez do método K-Medoids frente às variações sazonais e à combinação das variáveis utilizadas.

A utilização das regionalizações propostas representa uma abordagem promissora para otimizar o monitoramento ambiental e aprofundar a compreensão das interações entre os parâmetros analisados e outras características da bacia hidrográfica, como uso e ocupação do solo, a precipitação e a vazão. Nesse contexto, as geometrias das regiões delimitadas podem ser disponibilizadas mediante solicitação ao primeiro autor.

Agradecimentos

Ao *Norway's International Climate and Forest Initiative* (NICFI) pela disponibilização da imagem © 2024 Planet Labs Inc. À COPASA por ceder o acesso à represa e a estrutura necessária para a coleta de dados *in situ*. VLG agradece à CAPES pela bolsa de mestrado (88887.949362/2024-00). MK agradece à FAPESP (2021/04128-8).

Referências

- Abdelmalik, K.W., 2018. Role of statistical remote sensing for Inland water quality parameters prediction. *Egyptian Journal of Remote Sensing and Space Science* [online] 21. Disponível: <https://doi.org/10.1016/j.ejrs.2016.12.002>. Acesso: 11 dez. 2025.
- Adjovu, G.E., Stephen, H., James, D., Ahmad, S., 2023. Measurement of Total Dissolved Solids and Total Suspended Solids in Water Systems: A Review of the Issues, Conventional, and Remote Sensing Techniques. *Remote Sensing* [online] 15. Disponível: <https://doi.org/10.3390/rs15143534>. Acesso: 11 dez. 2025.
- Ahmed, M., Dars, G.H., Ahmed, S., Krakauer, N.Y., 2023. Analyzing drought trends over Sindh Province, Pakistan. *Natural Hazards* [online] 119. Disponível: <https://doi.org/10.1007/s11069-023-06082-y>. Acesso: 11 dez. 2025.
- Amadori, M., Bresciani, M., Giardino, C., Dijkstra, H.A., 2024. Slow response of surface water temperature to fast atmospheric variability reveals mixing heterogeneity in a deep lake. *Scientific Reports* [online] 14. Disponível: <https://doi.org/10.1038/s41598-024-58547-0>. Acesso: 11 dez. 2025.
- Armijos, E., Crave, A., Espinoza, J.C., Filizola, N., Espinoza-Villar, R., Ayes, I., Fonseca, P., Fraizy, P., Gutierrez, O., Vauchel, P., Camenen, B., Martinez, J.M., dos Santos, A., Santini, W., Cochonneau, G., Guyot, J.L., 2020. Rainfall control on Amazon sediment flux: Synthesis

- from 20 years of monitoring. *Environmental Research Communications* [online] 2. Disponível: <https://doi.org/10.1088/2515-7620/ab9003>. Acesso: 11 dez. 2025.
- Assunção, R.M., Neves, M.C., Câmara, G., da Costa Freitas, C., 2006. Efficient regionalization techniques for socio-economic geographical units using minimum spanning trees. *International Journal of Geographical Information Science* [online] 20. Disponível: <https://doi.org/10.1080/13658810600665111>. Acesso: 11 dez. 2025.
- Ateş, C., Kaymaz, Ö., Kale, H.E., Tekindal, M.A., 2019. Comparison of Test Statistics of Nonnormal and Unbalanced Samples for Multivariate Analysis of Variance in terms of Type-I Error Rates. *Computational and Mathematical Methods in Medicine* [online] 2019. Disponível: <https://doi.org/10.1155/2019/2173638>. Acesso: 11 dez. 2025.
- Attiah, G., Kheyrollah Pour, H., Scott, K.A., 2023. Lake surface temperature retrieved from Landsat satellite series (1984 to 2021) for the North Slave Region. *Earth System Science Data* [online] 15. Disponível: <https://doi.org/10.5194/essd-15-1329-2023>. Acesso: 11 dez. 2025.
- Aydin, O., Janikas, M.v., Assunção, R.M., Lee, T.H., 2021. A quantitative comparison of regionalization methods. *International Journal of Geographical Information Science* [online] 35. Disponível: <https://doi.org/10.1080/13658816.2021.1905819>. Acesso: 11 dez. 2025.
- Cartwright, P.J., Fearn, P.R.C.S., Branson, P., Cutler, M.V.W., O'leary, M., Browne, N.K., Lowe, R.J., 2021. Identifying Metocean Drivers of Turbidity Using 18 Years of MODIS Satellite Data: Implications for Marine Ecosystems under Climate Change. *Remote Sensing* [online] 13. Disponível: <https://doi.org/10.3390/rs13183616>. Acesso: 11 dez. 2025.
- Carvalho, B.C., Figueira, R.M.A., De Medeiros Fortunato, H.F., 2023. Spatio-temporal water quality variability and regionalization of tropical reservoirs based on Landsat imagery. *Journal of Applied Remote Sensing* [online] 17. Disponível: <https://doi.org/10.1117/1.jrs.17.014512>. Acesso: 11 dez. 2025.
- Cerutti, J.M.B., Holzman, R., Kiflawi, M., Fine, M., 2025. Regionalisation of Red Sea coral reefs based on remotely sensed environmental data identifies two distinct regions that align with large-scale climatic forcings. *Coral Reefs* [online]. Disponível: <https://doi.org/10.1007/s00338-025-02668-z>. Acesso: 11 dez. 2025.
- Chawla, I., Karthikeyan, L., Mishra, A.K., 2020. A review of remote sensing applications for water security: Quantity, quality, and extremes. *Journal of Hydrology* [online] 585. Disponível: <https://doi.org/10.1016/j.jhydrol.2020.124826>. Acesso: 11 dez. 2025.
- Cisty, M., Soldanova, V., Cyprich, F., Holubova, K., Simor, V., 2021. Suspended sediment modelling with hydrological and climate input data. *Journal of Hydroinformatics* [online] 23. Disponível: <https://doi.org/10.2166/hydro.2020.116>. Acesso: 11 dez. 2025.
- Coccia, C., Pintado, E., Paredes, Á.L., Aragonés, D., O'Ryan, D.C., Green, A.J., Bustamante, J., Díaz-Delgado, R., 2024. Modelling Water Depth, Turbidity and Chlorophyll Using Airborne Hyperspectral Remote Sensing in a Restored Pond Complex of Doñana National Park (Spain). *Remote Sensing* [online] 16. Disponível: <https://doi.org/10.3390/rs16162996>. Acesso: 11 dez. 2025.
- COPAM. Conselho Estadual de Política Ambiental, 1995. Deliberação Normativa COPAM nº 14, de 28 de dezembro de 1995: Dispõe sobre o enquadramento das águas do Rio Paraopeba. Belo Horizonte.
- COPAM/CERH-MG. Conselho Estadual de Política Ambiental e Conselho Estadual de Recursos Hídricos de Minas Gerais, 2022. Deliberação Normativa Conjunta COPAM-CERH/MG nº 8, de 21 de novembro de 2022: Classificação dos corpos de água e diretrizes ambientais para seu enquadramento, condições e padrões de lançamento de efluentes. Belo Horizonte.
- Dogliotti, A.I., Ruddick, K.G., Nechad, B., Doxaran, D., Knaeps, E., 2015. A single algorithm to retrieve turbidity from remotely-sensed data in all coastal and estuarine waters. *Remote Sensing of Environment* [online] 156. Disponível: <https://doi.org/10.1016/j.rse.2014.09.020>. Acesso: 11 dez. 2025.
- Dokulil, M.T., de Eyto, E., Maberly, S.C., May, L., Weyhenmeyer, G.A., Woolway, R.I., 2021. Increasing maximum lake surface temperature under climate change. *Climatic Change* [online] 165. Disponível:

- <https://doi.org/10.1007/s10584-021-03085-1>. Acesso: 11 dez. 2025.
- Dutkiewicz, S., Hickman, A.E., Jahn, O., Gregg, W.W., Mouw, C.B., Follows, M.J., 2015. Capturing optically important constituents and properties in a marine biogeochemical and ecosystem model. *Biogeosciences* [online] 12. Disponível: <https://doi.org/10.5194/bg-12-4447-2015>. Acesso: 11 dez. 2025.
- Entezami, A., Sarmadi, H., Saeedi Razavi, B., 2020. An innovative hybrid strategy for structural health monitoring by modal flexibility and clustering methods. *Journal of Civil Structural Health Monitoring* [online] 10. Disponível: <https://doi.org/10.1007/s13349-020-00421-4>. Acesso: 11 dez. 2025.
- EPA. U.S. Environmental Protection Agency, 1993. Method 180.1: Determination of turbidity by nephelometry (Revision 2.0). Washington, D.C.
- Evans, C., Gehrman, R., Greene, C., Blenis, S., MacKinnon, R., Newport, J., Vela, S., Smith, M., Sadeghi, Z., Matwin, S., Whidden, C., 2025. Monitoring harmful algae blooms in Darlings Lake, New Brunswick, using K-means clustering of multi-spectral imagery. *Frontiers in Remote Sensing* [online] 6. Disponível: <https://doi.org/10.3389/frsen.2025.1633491>. Acesso: 11 dez. 2025.
- Foga, S., Scaramuzza, P.L., Guo, S., Zhu, Z., Dilley, R.D., Beckmann, T., Schmidt, G.L., Dwyer, J.L., Joseph Hughes, M., Laue, B., 2017. Cloud detection algorithm comparison and validation for operational Landsat data products. *Remote Sensing of Environment* [online] 194. Disponível: <https://doi.org/10.1016/j.rse.2017.03.026>. Acesso: 11 dez. 2025.
- Gao, J., 2009. Bathymetric mapping by means of remote sensing: Methods, accuracy and limitations. *Progress in Physical Geography* [online] 33. Disponível: <https://doi.org/10.1177/0309133309105657>. Acesso: 11 dez. 2025.
- Gascon, F., Bouzinac, C., Thépaut, O., Jung, M., Francesconi, B., Louis, J., Lonjou, V., Lafrance, B., Massera, S., Gaudel-Vacaresse, A., Languille, F., Alhammoud, B., Viallefont, F., Pflug, B., Bieniarz, J., Clerc, S., Pessiot, L., Trémas, T., Cadau, E., Fernandez, V., 2017. Copernicus Sentinel-2A calibration and products validation status. *Remote Sensing* [online] 9. Disponível: <https://doi.org/10.3390/rs9060584>. Acesso: 11 dez. 2025.
- Herrera Carmona, J.C., Selvaraj, J.J., Giraldo, A., 2022. Dynamic regionalization of the Panama Bight, Eastern Tropical Pacific, using remote sensing data. *International Journal of Remote Sensing* [online] 43. Disponível: <https://doi.org/10.1080/01431161.2022.2063040>. Acesso: 11 dez. 2025.
- Huang, F.L., 2020. MANOVA: A Procedure Whose Time Has Passed? *Gifted Child Quarterly* [online] 64. Disponível: <https://doi.org/10.1177/0016986219887200>. Acesso: 11 dez. 2025.
- ISO. International Organization for Standardization, 2016. ISO 7027-1:2016 - Water quality — Determination of turbidity — Part 1: Quantitative methods. Genebra.
- IOCCG. International Ocean-Colour Coordinating Group, 2020. Synergy between ocean colour and biogeochemical/ecosystem models (S. Dutkiewicz, Ed.). Reports of the International Ocean-Colour Coordinating Group, No. 19. Dartmouth.
- Ishak, S.I., Sitanggang, I.S., Widodo, T., 2024. Comparison of K-Means and K-Medoids Algorithms for Clustering of Potential Flood-Prone Areas in Bengkulu Province. *IOP Conference Series: Earth and Environmental Science* [online] 1359. Disponível: <https://doi.org/10.1088/1755-1315/1359/1/012017>. Acesso: 11 dez. 2025.
- Kaufman, L., Rousseeuw, P. J, 1990. Partitioning Around Medoids (Program PAM). *Wiley Series in Probability and Statistics*, 68–125. Disponível: <https://doi.org/10.1002/9780470316801.ch2>. Acesso: 11 dez. 2025.
- Kavanaugh, M.T., Oliver, M.J., Chavez, F.P., Letelier, R.M., Muller-Karger, F.E., Doney, S.C., 2016. Seascapes as a new vernacular for pelagic ocean monitoring, management and conservation. *ICES Journal of Marine Science* [online] 73. Disponível: <https://doi.org/10.1093/icesjms/fsw086>. Acesso: 11 dez. 2025.
- Khazaei, B., Read, L.K., Casali, M., Sampson, K.M., Yates, D.N., 2022. GLOBathy, the global lakes bathymetry dataset. *Scientific Data* [online] 9. Disponível: <https://doi.org/10.1038/s41597-022-01132-9>. Acesso: 11 dez. 2025.
- Kim, T., Lee, H.D., Yang, S.H., Lee, G.H., Shin, J., Cha, Y.K., 2025. Long-term spatiotemporal variability and regime classification of Chlorophyll-a concentrations in Lake Erie using satellite products. *Harmful Algae* [online] 148.

- Disponível:
<https://doi.org/10.1016/j.hal.2025.102896>.
Acesso: 11 dez. 2025.
- Krug, L.A., Platt, T., Sathyendranath, S., Barbosa, A.B., 2017. Ocean surface partitioning strategies using ocean colour remote Sensing: A review. *Progress in Oceanography* [online] 155. Disponível:
<https://doi.org/10.1016/j.pocean.2017.05.013>.
Acesso: 11 dez. 2025.
- Kuhn, C., de Matos Valerio, A., Ward, N., Loken, L., Sawakuchi, H.O., Kampel, M., Richey, J., Stadler, P., Crawford, J., Striegl, R., Vermote, E., Pahlevan, N., Butman, D., 2019. Performance of Landsat-8 and Sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity. *Remote Sensing of Environment* [online] 224. Disponível:
<https://doi.org/10.1016/j.rse.2019.01.023>.
Acesso: 11 dez. 2025.
- Li, Z.L., Wu, H., Duan, S.B., Zhao, W., Ren, H., Liu, X., Leng, P., Tang, R., Ye, X., Zhu, J., Sun, Y., Si, M., Liu, M., Li, J., Zhang, X., Shang, G., Tang, B.H., Yan, G., Zhou, C., 2023. Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications. *Reviews of Geophysics* [online] 61. Disponível:
<https://doi.org/10.1029/2022RG000777>.
Acesso: 11 dez. 2025.
- Liu, K., Song, C., 2022. Modeling lake bathymetry and water storage from DEM data constrained by limited underwater surveys. *Journal of Hydrology* [online] 604. Disponível:
<https://doi.org/10.1016/j.jhydrol.2021.127260>.
Acesso: 11 dez. 2025.
- Magalhães Junior, A.P., Cota, G.E.M., Lemos, R.S., 2016. CONTRADIÇÕES E DESAFIOS PARA A PROTEÇÃO DE MANANCIAS HÍDRICOS EM MINAS GERAIS - OS CASOS DAS ÁREAS DE PROTEÇÃO ESPECIAL DE VARGEM DAS FLORES E SERRA AZUL - REGIÃO METROPOLITANA DE BELO HORIZONTE. *Caminhos De Geografia* [online] 17. Disponível:
<https://doi.org/10.14393/RCG176007>. Acesso: 11 dez. 2025.
- Main-Knorn, M., Pflug, B., Louis, J., Debaecker, V., Müller-Wilm, U., Gascon, F., 2017. Sen2Cor for Sentinel-2. In *Proceedings of SPIE 10427, Image and Signal Processing for Remote Sensing XXIII*, 1042704. Disponível:
<https://doi.org/10.1117/12.2278218>. Acesso: 11 dez. 2025.
- Martins, V.S., Barbosa, C.C.F., de Carvalho, L.A.S., Jorge, D.S.F., Lobo, F.L., de Moraes Novo, E.M.L., 2017. Assessment of Atmospheric Correction Methods for Sentinel-2 MSI Images Applied to Amazon Floodplain Lakes. *Remote Sensing* [online] 9. Disponível:
<https://doi.org/10.3390/rs9040322>. Acesso: 11 dez. 2025.
- Martinsen, K.T., Sand-Jensen, K., Selvan, R., 2023. Predicting lake bathymetry from the topography of the surrounding terrain using deep learning. *Limnology and Oceanography: Methods* [online] 21. Disponível:
<https://doi.org/10.1002/lom3.10573>. Acesso: 11 dez. 2025.
- Matsui, K., Kageyama, Y., 2022. Water pollution evaluation through fuzzy c-means clustering and neural networks using ALOS AVNIR-2 data and water depth of Lake Hosenko, Japan. *Ecological Informatics* [online] 70. Disponível:
<https://doi.org/10.1016/j.ecoinf.2022.101761>.
Acesso: 11 dez. 2025.
- Mélin, F., Vantrepotte, V., 2015. How optically diverse is the coastal ocean? *Remote Sensing of Environment* [online] 160. Disponível:
<https://doi.org/10.1016/j.rse.2015.01.023>.
Acesso: 11 dez. 2025.
- Meng, H., Zhang, J., Zheng, Z., Song, Y., Lai, Y., 2024. Classification of inland lake water quality levels based on Sentinel-2 images using convolutional neural networks and spatiotemporal variation and driving factors of algal bloom. *Ecological Informatics* [online] 80. Disponível:
<https://doi.org/10.1016/j.ecoinf.2024.102549>.
Acesso: 11 dez. 2025.
- Moreno, F.M., Tannuri, E.A., Cozman, F.G., 2023. Automatic Clustering of Metocean Conditions on the Brazilian Coast. *Journal of Offshore Mechanics and Arctic Engineering* [online] 145. Disponível: <https://doi.org/10.1115/1.4056618>.
Acesso: 11 dez. 2025.
- Nechad, B., Ruddick, K.G., Neukermans, G., 2009. Calibration and validation of a generic multisensor algorithm for mapping of turbidity in coastal waters. *Remote Sensing of the Ocean, Sea Ice, and Large Water Regions 2009* [online] 7473. Disponível:
<https://doi.org/10.1117/12.830700>. Acesso: 11 dez. 2025.
- Nechad, B., Ruddick, K.G., Park, Y., 2010. Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters. *Remote Sensing of Environment* [online] 114.

- Disponível:
<https://doi.org/10.1016/j.rse.2009.11.022>.
Acesso: 11 dez. 2025.
- Nguyen, V.S., Loisel, H., Vantrepotte, V., Mériaux, X., Tran, D.L., 2024. An Empirical Algorithm for Estimating the Absorption of Colored Dissolved Organic Matter from Sentinel-2 (MSI) and Landsat-8 (OLI) Observations of Coastal Waters. *Remote Sensing* [online] 16. Disponível: <https://doi.org/10.3390/rs16214061>. Acesso: 11 dez. 2025.
- Nitish, K., Indu, J., 2025. Evaluating interdependencies of lake water surface temperature and clarity. *Science of the Total Environment* [online] 966. Disponível: <https://doi.org/10.1016/j.scitotenv.2025.17869> 5. Acesso: 11 dez. 2025.
- Novianta, M.A., Syafrudin, Warsito, B., Rachmawati, S., 2025. Mapping of river water quality through spatial K'luster analysis by tree edge removal. *Ecological Engineering and Environmental Technology* [online] 26. Disponível: <https://doi.org/10.12912/27197050/195296>. Acesso: 11 dez. 2025.
- O'Brien, R.G., Kaiser, M.K., 1985. MANOVA method for analyzing repeated measures designs: An extensive primer. *Psychological Bulletin* [online] 97. Disponível: <https://doi.org/10.1037/0033-2909.97.2.316>. Acesso: 11 dez. 2025.
- O'Donnell, M.S., Edmunds, D.R., Aldridge, C.L., Heinrichs, J.A., Coates, P.S., Prochazka, B.G., Hanser, S.E., 2019. Designing multi-scale hierarchical monitoring frameworks for wildlife to support management: a sage-grouse case study. *Ecosphere* [online] 10. Disponível: <https://doi.org/10.1002/ecs2.2872>. Acesso: 11 dez. 2025.
- Powers, S.M., Barnard, M.A., Macleod, M.S., Miller, L.A., Wagner, N.D., 2023. Spatially Intensive Patterns of Water Clarity in Reservoirs Determined Rapidly With Sensor-Equipped Boats and Satellites. *Journal of Geophysical Research: Biogeosciences* [online] 128. Disponível: <https://doi.org/10.1029/2023JG007650>. Acesso: 11 dez. 2025.
- Reygondeau, G., Guidi, L., Beaugrand, G., Henson, S.A., Koubbi, P., MacKenzie, B.R., Sutton, T.T., Fioroni, M., Maury, O., 2018. Global biogeochemical provinces of the mesopelagic zone. *Journal of Biogeography* [online] 45. Disponível: <https://doi.org/10.1111/jbi.13149>. Acesso: 11 dez. 2025.
- Rosso, I., Mazloff, M.R., Talley, L.D., Purkey, S.G., Freeman, N.M., Maze, G., 2020. Water Mass and Biogeochemical Variability in the Kerguelen Sector of the Southern Ocean: A Machine Learning Approach for a Mixing Hot Spot. *Journal of Geophysical Research: Oceans* [online] 125. Disponível: <https://doi.org/10.1029/2019JC015877>. Acesso: 11 dez. 2025.
- Rousseeuw, P.J., 1987. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics* [online] 20. Disponível: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7). Acesso: 11 dez. 2025.
- Santos, A.L.V., Caldeira, A.B., Junior, I.S., 2018. Recolhimento de Esgoto na Área de Proteção Ambiental Vargem das Flores/MG. *Revista Do Departamento De Geografia* [online] 35. Disponível: <https://doi.org/10.11606/rdg.v35i0.140604>. Acesso: 11 dez. 2025.
- Santos, R., Gonçalves, G., 2023. REGIONALIZAÇÃO DA TRANSIÇÃO DE FECUNDIDADE NO BRASIL EM 1991, 2000 e 2010. *Revista De Geografia - PPGeo - UFJF* [online] 13. Disponível: <https://doi.org/10.34019/2236-837x.2023.v13.39497>. Acesso: 11 dez. 2025.
- Santos, S. P., 2012. Morfometria, compartimentação e hidrodinâmica de um reservatório periurbano tropical: Prognósticos sobre o tempo de vida útil do Reservatório de Vargem das Flores, Minas Gerais – Brasil [Dissertação de mestrado, Universidade Federal de Minas Gerais]. Repositório Institucional da UFMG. Disponível: <http://hdl.handle.net/1843/BUOS-92YPGV>. Acesso: 11 dez. 2025.
- Sent, G., Biguino, B., Favareto, L., Cruz, J., Sá, C., Dogliotti, A.I., Palma, C., Brotas, V., Brito, A.C., 2021. Deriving Water Quality Parameters Using Sentinel-2 Imagery: A Case Study in the Sado Estuary, Portugal. *Remote Sensing* [online] 13. Disponível: <https://doi.org/10.3390/rs13051043>. Acesso: 11 dez. 2025.
- Spyrakos, E., O'Donnell, R., Hunter, P.D., Miller, C., Scott, M., Simis, S.G.H., Neil, C., Barbosa, C.C.F., Binding, C.E., Bradt, S., Bresciani, M., Dall'Olmo, G., Giardino, C., Gitelson, A.A., Kutser, T., Li, L., Matsushita, B., Martinez-Vicente, V., Matthews, M.W., Tyler, A.N.,

2018. Optical types of inland and coastal waters. *Limnology and Oceanography* [online] 63. Disponível: <https://doi.org/10.1002/lno.10674>. Acesso: 11 dez. 2025.
- Stähle, L., Wold, S., 1990. Multivariate analysis of variance (MANOVA). *Chemometrics and Intelligent Laboratory Systems* [online] 9. Disponível: [https://doi.org/10.1016/0169-7439\(90\)80094-m](https://doi.org/10.1016/0169-7439(90)80094-m). Acesso: 11 dez. 2025.
- Taylor, C.A., Rising, J., 2021. Tipping point dynamics in global land use. *Environmental Research Letters* [online] 16. Disponível: <https://doi.org/10.1088/1748-9326/ac3c6d>. Acesso: 11 dez. 2025.
- Thorndike, R.L., 1953. Who belongs in the family? *Psychometrika* [online] 18. Disponível: <https://doi.org/10.1007/bf02289263>. Acesso: 11 dez. 2025.
- Torres-Bejarano, F., Arteaga-Hernández, F., Rodríguez-Ibarra, D., Mejía-Ávila, D., González-Márquez, L.C., 2021. Water quality assessment in a wetland complex using Sentinel 2 satellite images. *International Journal of Environmental Science and Technology* [online] 18. Disponível: <https://doi.org/10.1007/s13762-020-02988-3>. Acesso: 11 dez. 2025.
- Tran, T.K., Duforêt-Gaurier, L., Vantrepotte, V., Ferreira Jorge, D.S., Mériaux, X., Cauvin, A., d'Andon, F., Loisel, H., 2019. Deriving Particulate Organic Carbon in Coastal Waters from Remote Sensing: Inter-Comparison Exercise and Development of a Maximum Band-Ratio Approach. *Remote Sensing* [online] 11. Disponível: <https://doi.org/10.3390/rs11232849>. Acesso: 11 dez. 2025.
- Tukey, J. W., 1977. *Exploratory data analysis*. Addison-Wesley. Disponível: https://doi.org/10.1007/978-0-387-32833-1_136. Acesso: 11 dez. 2025.
- USGS. United States Geological Survey, 2021. Landsat 4-7 Collection 2 (C2) Level 2 Science Product (L2SP) Guide. Sioux Falls.
- USGS. United States Geological Survey, 2024. Landsat 8-9 Collection 2 (C2) Level 2 Science Product (L2SP) Guide. Sioux Falls.
- Vantrepotte, V., Loisel, H., Dessailly, D., Mériaux, X., 2012. Optical classification of contrasted coastal waters. *Remote Sensing of Environment* [online] 123. Disponível: <https://doi.org/10.1016/j.rse.2012.03.004>. Acesso: 11 dez. 2025.
- Verdonschot, P.F.M., Spears, B.M., Feld, C.K., Brucet, S., Keizer-Vlek, H., Borja, A., Elliott, M., Kernan, M., Johnson, R.K., 2013. A comparative review of recovery processes in rivers, lakes, estuarine and coastal waters. *Hydrobiologia* [online] 704. Disponível: <https://doi.org/10.1007/s10750-012-1294-7>. Acesso: 11 dez. 2025.
- Wang, F., Qing, S., Sa, C., Lai, Q., Chang, A., 2024. Remote Sensing Evaluation of Trophic Status in the Daihai Lake Based on Fuzzy Classification. *Water (Switzerland)* [online] 16. Disponível: <https://doi.org/10.3390/w16213032>. Acesso: 11 dez. 2025.
- 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* [online] 14. Disponível: <https://doi.org/10.1109/JSTARS.2021.3101475>. Acesso: 11 dez. 2025.
- Warren, M.A., Simis, S.G.H., Selmes, N., 2021. Complementary water quality observations from high and medium resolution Sentinel sensors by aligning chlorophyll-a and turbidity algorithms. *Remote Sensing of Environment* [online] 265. Disponível: <https://doi.org/10.1016/j.rse.2021.112651>. Acesso: 11 dez. 2025.
- Wei, J., Wang, M., Mikelsons, K., Jiang, L., Kratzer, S., Lee, Z., Moore, T., Sosik, H.M., van der Zande, D., 2022. Global satellite water classification data products over oceanic, coastal, and inland waters. *Remote Sensing of Environment* [online] 282. Disponível: <https://doi.org/10.1016/j.rse.2022.113233>. Acesso: 11 dez. 2025.
- Xiong, J., Zheng, Y., Zhang, J., Quan, F., Lu, H., Zeng, H., 2023. Impact of climate change on coastal water quality and its interaction with pollution prevention efforts. *Journal of Environmental Management* [online] 325. Disponível: <https://doi.org/10.1016/j.jenvman.2022.116557>. Acesso: 11 dez. 2025.
- Yao, J., Zhang, Q., Ye, X., Zhang, D., Bai, P., 2018. Quantifying the impact of bathymetric changes on the hydrological regimes in a large floodplain lake: Poyang Lake. *Journal of Hydrology* [online] 561. Disponível: <https://doi.org/10.1016/j.jhydrol.2018.04.035>. Acesso: 11 dez. 2025.
- Zhang, M., Leppäranta, M., Korhola, A., Kirchner, N., Granebeck, A., Schenk, F., Weckström, K.,

Heikkilä, M., Weckström, J., 2024. Drivers of spatio-temporal variations in summer surface

water temperatures of Arctic Fennoscandian lakes (2000–21). *Polar Research* [online] 43. Disponível: <https://doi.org/10.33265/polar.v43.9580>. Acesso: 11 dez. 2025.