

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

### APLICAÇÃO DO ALGORITMO STATISTICAL MONO-WINDOW NA ESTIMATIVA DA TEMPERATURA DA SUPERFÍCIE DA ÁGUA EM RESERVATÓRIOS DE ABASTECIMENTO PÚBLICO

Jackson Rodrigues Primo<sup>1</sup>; Talita Fernanda das Graças Silva<sup>2</sup> & Lino Augusto Sander de  
Carvalho<sup>3</sup>

**Abstract:** Remote sensing is an important tool for monitoring the Earth's surface, serving as a complement to data obtained through *in situ* measurements, which are often undersampled in water body. This study assessed the performance of the Statistical Mono-Window algorithm to estimate the surface water temperature of the Rio Manso, Serra Azul, and Vargem das Flores reservoirs in the Metropolitan Region of Belo Horizonte (MG). The algorithm validation was carried out based on *in situ* data collected between 1984 and 2021. The results indicated satisfactory performance of the algorithm, with the Vargem das Flores reservoir standing out, showing a Pearson correlation coefficient ( $r$ ) of 0.88, a root mean square error (RMSE) of 1.55 °C, and a mean absolute percentage error (MAPE) of 5.01%. The Rio Manso reservoir showed good correlation ( $r = 0.85$ ), with an RMSE of 2.49 °C and a MAPE of 7.66%. The Serra Azul reservoir exhibited performance similar to that of Rio Manso ( $r = 0.83$ ; RMSE = 2.21 °C; MAPE = 6.81%). The algorithm's performance for the TM, ETM+, and TIRS sensors was equivalent. The results demonstrate the applicability of the algorithm for estimating surface temperature in aquatic environments using remote sensing imagery.

**Resumo:** O sensoriamento remoto é uma importante ferramenta para o monitoramento da superfície terrestre, servindo como complemento aos dados obtidos por meio de medições *in situ*, frequentemente subamostradas em corpos d'água. Este estudo avaliou o desempenho do algoritmo *Statistical Mono-Window* na estimativa da temperatura da superfície da água dos reservatórios Rio Manso, Serra Azul e Vargem das Flores na Região Metropolitana de Belo Horizonte (MG). A validação do algoritmo foi realizada com base em dados *in situ* coletados entre 1984 e 2021. Os resultados indicaram desempenho satisfatório do algoritmo, destacando-se o reservatório de Vargem das Flores, com coeficiente de correlação de Pearson ( $r$ ) de 0,88, raiz do erro quadrático médio (RMSE) de 1,55 °C e erro percentual absoluto médio (MAPE) de 5,01%. O reservatório do Rio Manso apresentou boa correlação ( $r = 0,85$ ), com RMSE de 2,49 °C e MAPE de 7,66%. O reservatório Serra Azul obteve desempenho semelhante ao de Rio Manso ( $r = 0,83$ ; RMSE = 2,21 °C; MAPE = 6,81%). O desempenho do algoritmo para os sensores TM, ETM+ e TIRS foi equivalente. Os resultados demonstram a aplicabilidade do algoritmo na estimativa da temperatura superficial em ambientes aquáticos utilizando imagens de sensoriamento remoto.

**Palavras-Chave** – Landsat, Validação de Algoritmo

<sup>1</sup>Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos, Universidade Federal de Minas Gerais. jacksonrodrigues14@hotmail.com

<sup>2</sup>Departamento de Engenharia Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais. talita.silva@ehr.ufmg.br

<sup>3</sup>Instituto de Geociências da Universidade Federal do Rio de Janeiro. lino.sander@igeo.ufrj.br

## 1- INTRODUÇÃO

A temperatura da água é um parâmetro físico essencial para a compreensão do ciclo hidrológico, dos processos de mistura e estratificação em reservatórios, bem como das mudanças climáticas (Sharaf *et al.*, 2019). O monitoramento da temperatura da água permite compreender os processos dinâmicos que ocorrem nos sistemas aquáticos (Barbosa; Novo; Martins, 2019), entretanto, o método convencional normalmente é caro, subamostrado e pouco frequente para grandes massas d'água (Alcântara *et al.*, 2010). Neste sentido, o sensoriamento remoto permite aumentar a frequência e abrangência espacial do monitoramento da temperatura de superfície da água (Alcântara *et al.*, 2010; Dörnhöfer; Oppelt, 2016; Sharaf *et al.*, 2019).

Diversos satélites podem ser utilizados para o monitoramento da temperatura de superfície (Li *et al.*, 2023); dentre eles, destacam-se os satélites Landsat, que possuem alta resolução espacial, um longo período de monitoramento e fazem parte do único programa com uma série temporal de quatro décadas (Barbosa; Novo; Martins, 2019; Li *et al.*, 2023). A missão Landsat permite o monitoramento de diversas características da superfície terrestre. A partir do Landsat 4, foi incluído o sensor termal, sendo utilizados o sensor TM (Thematic Mapper) nos satélites Landsat 4 e 5, o sensor ETM+ (Enhanced Thematic Mapper Plus) no Landsat 7, e o sensor TIRS (Thermal Infrared Sensor) nos satélites Landsat 8 e 9 (USGS, 2020).

A série de satélites Landsat é importante para o monitoramento de corpos d'água de pequeno a médio porte, devido à sua resolução espacial adequada para esse tipo de análise (Attiah; Kheyrollah Pour; Scott, 2023; Pedreros-Guarda *et al.*, 2021). A resolução temporal do Landsat é de 16 dias, e os produtos provenientes dos sensores termais deste satélite têm sido utilizados em diversos estudos que envolvem análise de séries temporais de temperatura. Os sensores termais a bordo dos satélites desta missão são capazes de captar a radiação emitida pela superfície da Terra, no entanto, essa radiação sofre interferência dos componentes presentes na atmosfera (Esteves, 2011). Para corrigir os efeitos atmosféricos foram desenvolvidos diversos algoritmos que possibilitam a estimativa da temperatura da superfície terrestre (Li *et al.*, 2023).

Vieira (2019) avaliou o desempenho do algoritmo *Single Channel Generalized Method* (SCGM) desenvolvido por Jiménez-Muñoz e Sobrino (2003) na obtenção da temperatura de superfície da água no reservatório de Serra Azul utilizando os sensores termais do Landsat 5 e 7 entre 1984 e 2002. Wermuth *et al.* (2022) avaliaram os algoritmos *Statistical Mono-Window* (SMW) e o *Split-Window* para estimar a temperatura da superfície da água do reservatório da Pampulha (Belo Horizonte, MG) a partir de imagens Landsat 8. Para o mesmo reservatório, Souza *et al.* (2023) analisaram o potencial de utilização dos dados de temperatura de superfície da água da coleção *USGS Landsat 8 Level 2, Collection 2, Tier 1* disponíveis na Plataforma *Google Earth Engine* (GEE) e provenientes de um algoritmo *Single Channel*.

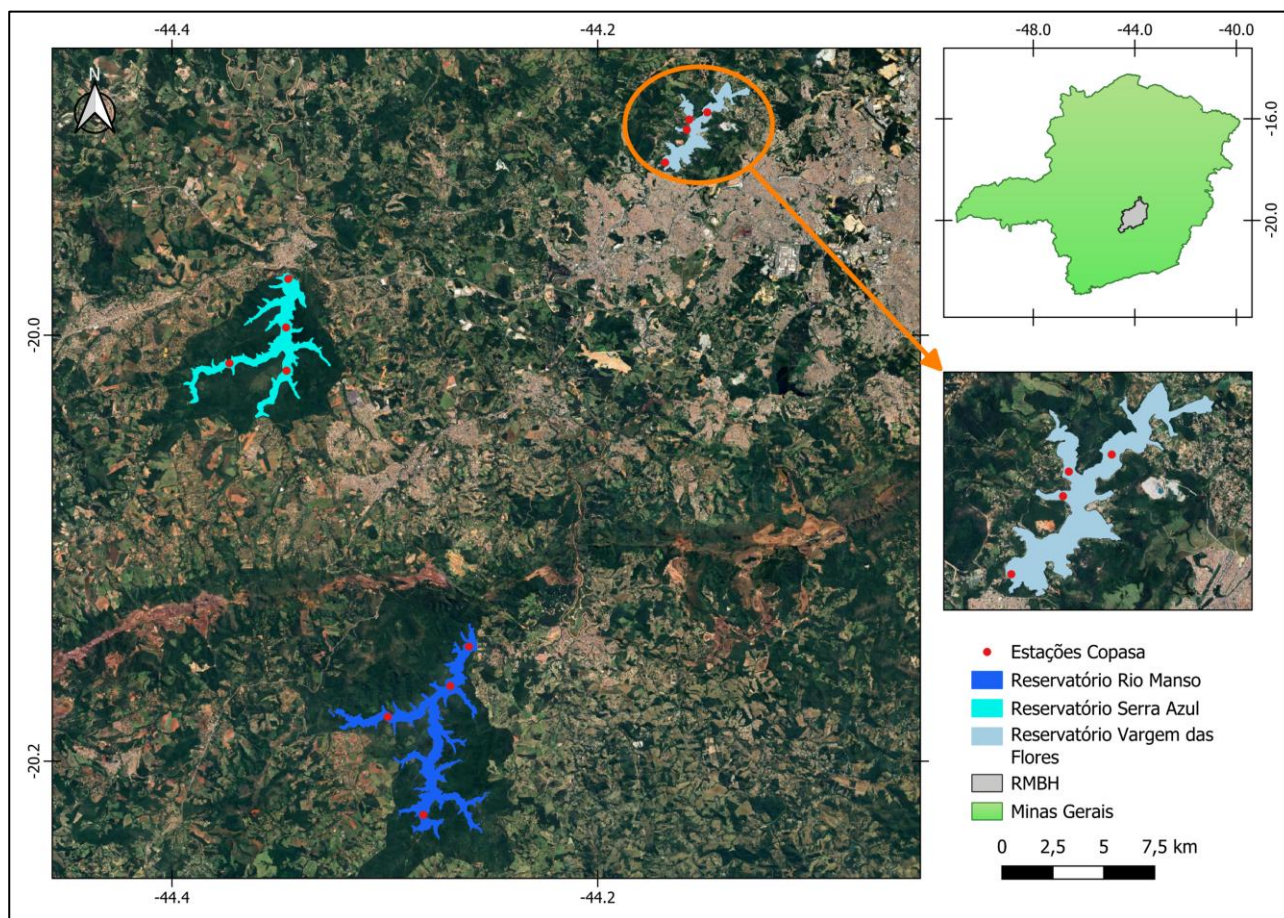
Este trabalho tem como objetivo avaliar o desempenho do algoritmo *Statistical Mono-Window* para a obtenção da temperatura da superfície da água em reservatórios de abastecimento público da Região Metropolitana de Belo Horizonte, utilizando os satélites Landsat 5, 7 e 8. Diferentemente de outros estudos realizados na região, que se concentraram em apenas um único reservatório, este trabalho abrange múltiplos mananciais e um período de 37 anos.

## 2- METODOLOGIA

## 2.1 Área de estudo

Os reservatórios selecionados para esse estudo estão localizados na Região Metropolitana de Belo Horizonte (RMBH), Minas Gerais (Figura 1). A área está inserida em um clima tropical, caracterizado por estações bem definidas: o período chuvoso, com temperaturas mais elevadas, ocorre de outubro a março, enquanto o período seco, com temperaturas mais amenas, abrange os meses de abril a setembro (Nunes, 2018).

Figura 1 – Localização dos reservatórios e dos pontos de monitoramento



Os três reservatórios selecionados são utilizados para o abastecimento público da RMBH. As características morfométricas desses reservatórios estão apresentadas na Tabela 1.

Tabela 1 – Características morfométricas dos reservatórios

Reservatório	Área [Km²]	Volume [hm³]	Profundidade máxima [m]	Profundidade média [m]	Fonte
Rio Manso	10,76	133,889	40,3	12,4	(Icatu Meio Ambiente Ltda, 2013a)
Serra Azul	7,38	93,565	47,3	12,6	(Icatu Meio Ambiente Ltda, 2013b)
Vargem das Flores	5,15	29,007	21,4	5,6	(Santos, 2012)



## 2.2. Dados *in situ*

A Copasa realiza o monitoramento *in situ* dos reservatórios, e os dados utilizados neste estudo foram disponibilizados por meio de uma parceria de cooperação técnico-científica com a Universidade Federal de Minas Gerais (UFMG). Dentre os diversos parâmetros monitorados, destaca-se a temperatura da água, utilizada neste trabalho para a validação do algoritmo SMW. Para a análise, foram selecionadas apenas as temperaturas de amostras coletadas até 0,5 m de profundidade.

## 2.3. Algoritmo *Statistical Mono-Window* (SMW)

O algoritmo *Statistical Mono-Window* foi desenvolvido pelo *Climate Monitoring Satellite Application Facility* (CM-SAF) para obter a temperatura de superfície terrestre do *Meteosat First and Second Generation* (Duguay-Tetzlaff *et al.*, 2015). Este algoritmo foi implementado por Ermida *et al.* (2020) na plataforma *Google Earth Engine* para a série Landsat 4, 5, 7, 8 e 9. Neste estudo, foram utilizadas apenas as imagens do Landsat 5, 7 e 8 compreendendo o período de 1984 a 2021. O algoritmo SMW baseia-se na linearização da equação de transferência radiativa e na relação empírica entre a temperatura de superfície terrestre e a temperatura de brilho no topo da atmosfera – eq. 1 (Duguay-Tetzlaff *et al.*, 2015).

$$LST = A \frac{Tb}{\varepsilon} + B \frac{1}{\varepsilon} + C \quad (1)$$

Onde, *LST* - temperatura de superfície (K); *Tb* - temperatura de brilho no topo da atmosfera (K);  $\varepsilon$  - emissividade da água; *A*, *B* e *C* - coeficientes das regressões lineares.

Os coeficientes da eq. 1 foram obtidos individualmente para cada sensor com base em regressões lineares aplicadas a 10 classes de intervalo de conteúdo de vapor d'água na atmosfera (Ermida *et al.*, 2020). Para a obtenção da temperatura da superfície da água, foi considerado um buffer de 60 metros a partir das coordenadas das estações de monitoramento.

## 2.4. Avaliação de desempenho do algoritmo SMW

A avaliação da eficiência do algoritmo SMW foi realizada por meio da comparação entre a temperatura da superfície da água estimada por sensoriamento remoto e os dados de monitoramento *in situ*. Para isso, foram utilizados pixels localizados dentro de um buffer de 60 metros em torno das coordenadas das estações de monitoramento e admitiu-se um intervalo de  $\pm 1$  dia entre as datas de passagem do satélite e do monitoramento *in situ*. A aplicação desse critério resultou na seleção de 120 imagens e 191 pares de dados para os locais de estudo. Para garantir a qualidade da análise, foram realizadas inspeções visuais nas imagens selecionadas com o objetivo de identificar a presença de nuvens, sombras e outros fatores que pudessem influenciar as estimativas da temperatura da superfície da água.

Tabela 2 – Quantidade de pares de dados (temperatura estimada e *in situ*) por reservatório em cada etapa de filtragem.

Reservatório	Pares antes da Inspeção Visual	Pares após a Inspeção Visual
Rio Manso	58	51
Serra Azul	66	62
Vargem das Flores	67	57

A avaliação do desempenho do algoritmo SMW foi realizada com base na comparação entre a temperatura estimada e a temperatura *in situ* (amostras), utilizando o coeficiente de correlação linear de Pearson ( $r$ ), a raiz do erro quadrático médio (RMSE) e o erro percentual médio absoluto (MAPE).

### 3- RESULTADOS E DISCUSSÃO

#### 3.1 Desempenho do SMW na obtenção da temperatura de superfície da água

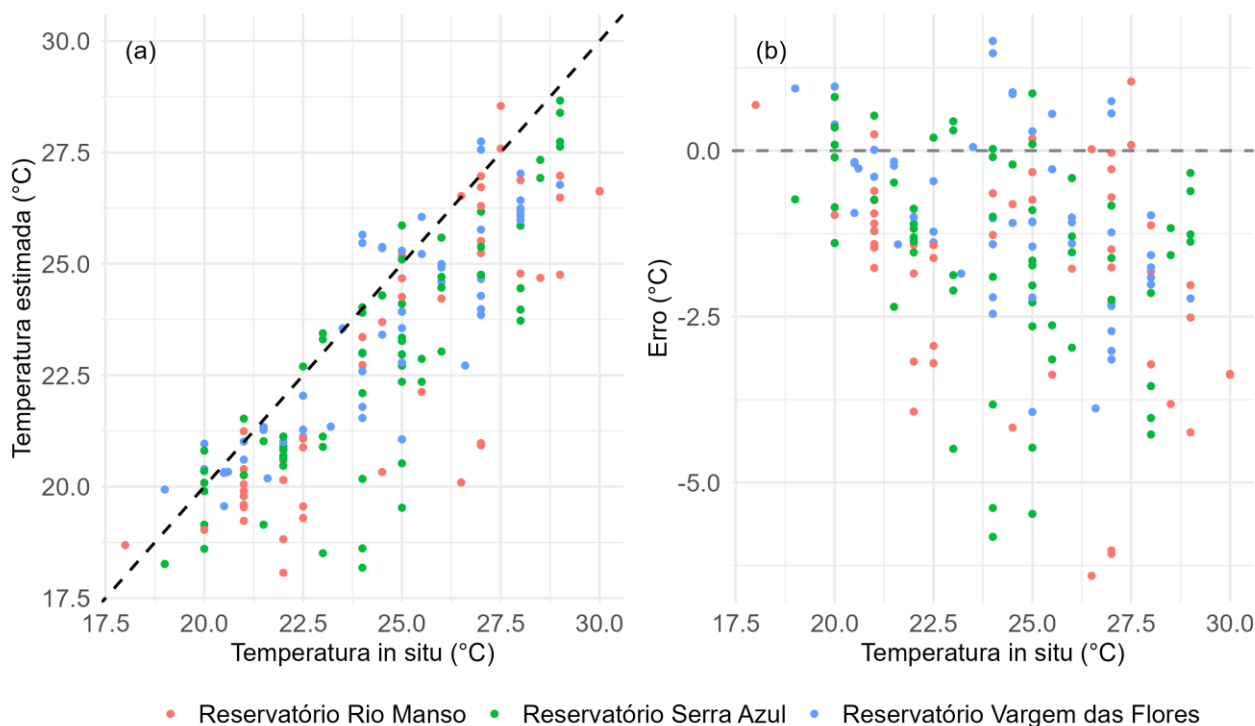
A Tabela 3 mostra que o algoritmo SMW apresentou desempenho superior no reservatório Vargem das Flores, enquanto, para os reservatórios Rio Manso e Serra Azul, o desempenho foi semelhante. Além disso, os valores máximos e mínimos da temperatura observada e da estimada não diferem de forma significativamente.

Tabela 3 – Métricas de desempenho do algoritmo SMW por reservatório

Reservatório	Correlação de Pearson	RMSE (°C)	MAPE (%)	Temp. mínima <i>in situ</i>	Temp. mínima. SMW	Temp. máxima. <i>in situ</i>	Temp. máxima. SMW
Rio Manso	0,85	2,49	7,66	18	18,07	30	28,54
Serra Azul	0,83	2,21	6,81	19	18,18	29	28,66
Vargem das Flores	0,88	1,55	5,01	19	19,56	29	29,85

De modo geral, os resultados apresentado na tabela 3 são equiparáveis aos encontrados por Vieira (2019) para o reservatório de Serra Azul utilizando o algoritmo SGCM para estimar a temperatura da superfície da água e os resultados foram considerados satisfatórios, embora tenha sido observada uma tendência à subestimação. Os valores de MAE, MAPE, coeficiente de determinação ( $R^2$ ), RMSE e viés obtidos pela autora na validação do algoritmo SCGM foram, respectivamente, 1,68 °C, 7%, 0,73, 2,22 °C e -1,31 °C. Além disso, o algoritmo SMW também apresenta tendência à subestimação da temperatura, especialmente nas faixas de maior temperatura (Figura 2).

Figura 2 – Temperatura da água estimada pelo SMW (a) e erro de estimativa em função da medição *in situ* (b)



A subestimação da temperatura da superfície da água pode comprometer as análises de séries históricas de temperatura em reservatórios. Nesse sentido, erros sistemáticos na estimativa da temperatura podem introduzir vieses nas séries temporais, afetando a detecção de tendências e a interpretação de possíveis alterações no regime térmico dos corpos hídricos.

Adicionalmente, observa-se que a grande maioria dos dados de temperatura da água fornecidos pela Copasa apresenta valores inteiros ou terminados em 0,5, o que possivelmente está relacionado às características do equipamento utilizado na medição das amostras (Figura 2). Essa precisão do equipamento pode representar uma fonte complementar de incerteza no processo de validação do algoritmo.

### 3.2 SMW e os sensores termais do Landsat

O algoritmo SMW apresentou uma correlação de Pearson de 0,88 para o sensor TIRS do Landsat 8, evidenciando uma forte relação linear entre os dados estimados e observados. Por sua vez, o sensor ETM+ do Landsat 7 obteve os menores valores de RMSE (1,98 °C) e MAPE (5,81%), indicando melhor desempenho nas estimativas, tanto em termos absolutos quanto percentuais. O sensor TM do Landsat 5 apresentou o desempenho inferior entre os sensores avaliados, embora todos tenham produzido resultados considerados satisfatórios. Os achados deste estudo são consistentes com os RMSE obtidos por Ermida *et al.* (2020) em seu exercício de validação.

Tabela 4 - Métricas de desempenho do algoritmo SMW por sensor

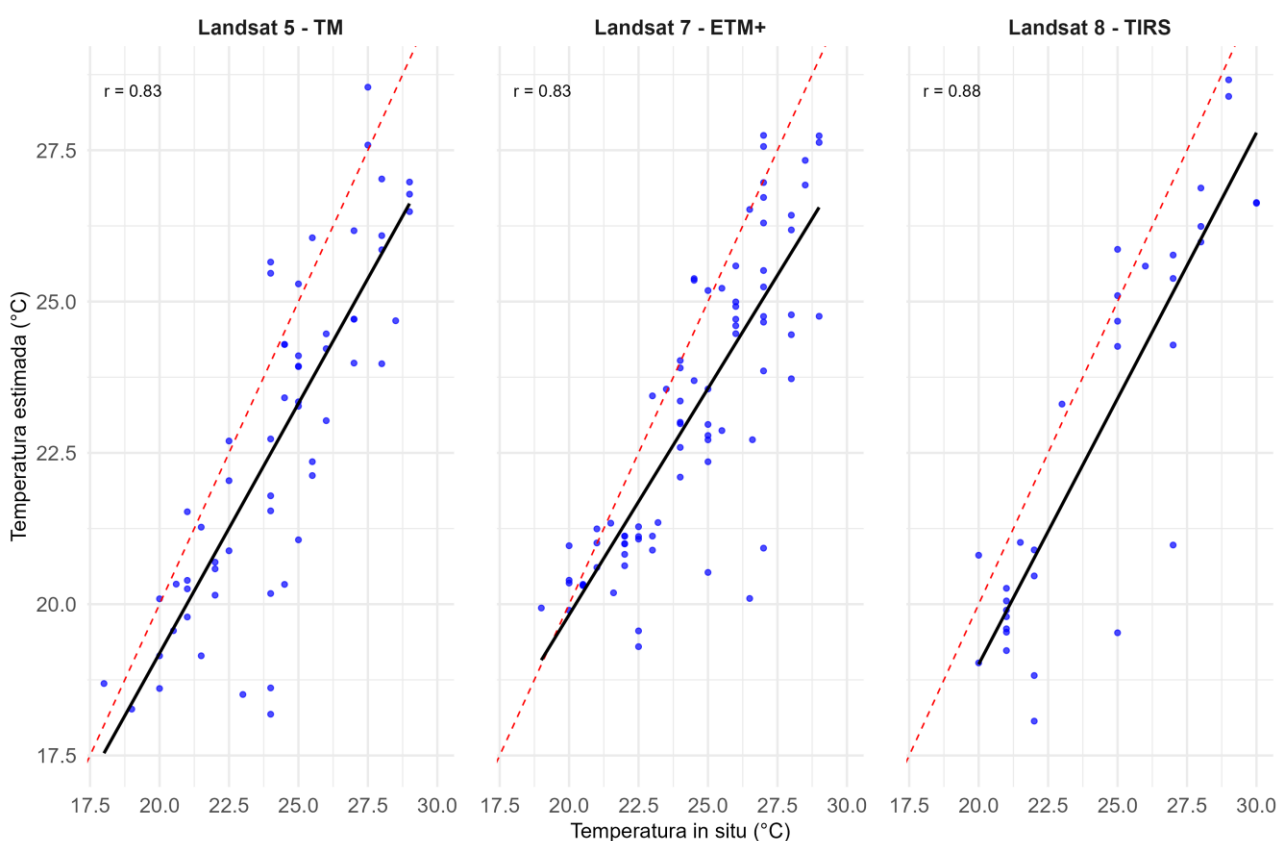
Sensor	Correlação de Pearson	RMSE (°C)	MAPE (%)
Landsat 5 - TM	0,83	2,23	7,20
Landsat 7 - ETM+	0,83	1,98	5,81
Landsat 8 - TIRS	0,88	2,19	6,74

Os resultados apresentados na Tabela 4 são superiores aos de outros estudos já realizados na RMBH utilizando o Landsat 8 e algoritmos de canal único. Para a Lagoa da Pampulha, Wermuth *et al.* (2022) aplicaram os algoritmos SMW e SW, obtendo um RMSE de 2,21 °C e um coeficiente de determinação ( $R^2$ ) de 0,29 para o SMW, enquanto o SW apresentou RMSE de 1,48 °C e  $R^2$  de 0,63. Por sua vez, Souza *et al.* (2023) analisaram o potencial de utilização de dados térmicos do algoritmo *single channel* da coleção *Landsat 8 Level 2, Collection 2, Tier 1* do GEE, também para o mesmo reservatório. O produto apresentou desempenho razoável, com coeficiente de correlação de Pearson ( $r$ ) igual a 0,70 e erro quadrático médio (RMSE) de 2,90 °C.

Destaca-se que os resultados obtidos no presente trabalho foram ligeiramente superiores, o que pode estar relacionado ao intervalo de pareamento entre as temperaturas estimadas e *in situ*. Contudo, os vieses para o Landsat 5, 7 e 8 foram de -1,56°C, -1,30°C e -1,53°C, respectivamente, valores inferiores à exatidão geral reportada por Ermida e colaboradores.

A seguir apresenta-se a figura 3 com a temperatura estimada por sensores.

Figura 3 – Temperatura estimada versus observada por sensor. A linha vermelha pontilhada representa a relação linear 1:1 e a linha preta contínua representa a tendência.



De maneira geral, conforme indicado anteriormente, os resultados do algoritmo SMW foram sutilmente superiores para o sensor ETM+, em termos de RMSE e MAPE. No entanto, é importante destacar que, para esse sensor, houve uma quantidade maior de pares de amostras *in situ* versus estimadas (Figura 3), quando comparado aos demais sensores: 59, 79 e 32 pares para os sensores Landsat 5, 7 e 8, respectivamente.

#### 4- CONCLUSÃO

Os resultados obtidos para os três reservatórios foram satisfatórios. Dentre os reservatórios, o de Vargem das Flores apresentou o melhor desempenho, com correlação de Pearson de 0,88, raiz do erro quadrático médio de 1,55 °C e erro percentual absoluto médio de 5,01%. O reservatório do Rio Manso, embora tenha registrado  $r$  de 0,85, apresentou um RMSE de 2,49 °C e MAPE de 7,66%. Já o reservatório Serra Azul obteve resultados semelhantes aos de Rio Manso, com correlação de Pearson de 0,83, RMSE de 2,21°C e MAPE de 6,81%.

No que se refere ao desempenho dos sensores, observou-se um comportamento geral semelhante entre eles. No entanto, o sensor *Enhanced Thematic Mapper Plus* (ETM+), do satélite Landsat 7, apresentou desempenho superior em relação aos sensores térmicos do Landsat 5 (*Thematic Mapper* – TM) e do Landsat 8 (*Thermal Infrared Sensor* – TIRS) nas métricas RMSE (1,98 °C) e MAPE (5,81%). Por outro lado, o sensor TIRS destacou-se por apresentar a maior correlação com os dados observados.

## AGRADECIMENTOS

Agradecemos à Escola de Engenharia da UFMG pelo apoio e à CAPES pelo financiamento da bolsa de pesquisa do primeiro autor, ao CNPq e à FAPEMIG pelas bolsas de produtividade em pesquisa concedidas aos coautores. Agradecemos também à Companhia de Saneamento de Minas Gerais pelos dados fornecidos para o desenvolvimento deste estudo.

## REFERÊNCIAS

- ALCÂNTARA, E. H. *et al.* *Remote sensing of water surface temperature and heat flux over a tropical hydroelectric reservoir*. *Remote Sensing of Environment*, v. 114, n. 11, p. 2651–2665, 2010.
- ATTIAH, G.; KHEYROLLAH POUR, H.; SCOTT, K. A. *Lake surface temperature retrieved from Landsat satellite series (1984 to 2021) for the North Slave Region*. *Earth System Science Data*, v. 15, n. 3, p. 1329–1355, 2023.
- BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. *Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações*. 1ªed. São José dos Campos: Instituto Nacional de Pesquisa Espaciais - INPE, 2019.
- DÖRNHÖFER, K.; OPPELT, N. *Remote sensing for lake research and monitoring – Recent advances*. *Ecological Indicators*, v. 64, p. 105–122, 2016.
- DUGUAY-TETZLAFF, A. *et al.* *Meteosat Land Surface Temperature Climate Data Record: Achievable Accuracy and Potential Uncertainties*. *Remote Sensing*, v. 7, n. 10, p. 13139–13156, 2015.
- ERMIDA, S. L. *et al.* *Google Earth Engine Open-Source Code for Land Surface Temperature Estimation from the Landsat Series*. *Remote Sensing*, v. 12, n. 9, p. 1471, 2020.
- ESTEVES, F. A. *Fundamentos de limnologia*. Rio de Janeiro: Editora Interciência, 2011.



ICATU MEIO AMBIENTE LTDA. *Estudos morfométricos e batimétricos no reservatório do Rio Manso - COPASA*. Belo Horizonte: Companhia de Saneamento de Minas Gerais - COPASA, 2013a. Disponível em: [https://www.rmpcecolgia.com/consultorias/consultoria\\_rmpe03.pdf](https://www.rmpcecolgia.com/consultorias/consultoria_rmpe03.pdf). .

ICATU MEIO AMBIENTE LTDA. *Estudos morfométricos e batimétricos no reservatório Serra Azul - COPASA*. Belo Horizonte: Companhia de Saneamento de Minas Gerais - COPASA, 2013b. Disponível em: [https://www.rmpcecolgia.com/consultorias/consultoria\\_rmpe04.pdf](https://www.rmpcecolgia.com/consultorias/consultoria_rmpe04.pdf). .

JIMÉNEZ-MUÑOZ, J. C.; SOBRINO, J. A. *A generalized single-channel method for retrieving land surface temperature from remote sensing data*. Journal of Geophysical Research: Atmospheres, v. 108, n. D22, 2003. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2003JD003480>. Acesso em: 20 jan. 2025.

LI, Z.-L. *et al. Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications*. Reviews of Geophysics, v. 61, n. 1, p. e2022RG000777, 2023.

NUNES, A. de A. *Tendências em eventos extremos de precipitação na Região Metropolitana de Belo Horizonte: detecção, impactos e adaptabilidade*. 2018. 191 f. Tese de doutorado. Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos - Universidade Federal de Minas Gerais, Belo Horizonte, 2018.

PEDREROS-GUARDA, M. *et al. A Google Earth Engine Application to Retrieve Long-Term Surface Temperature for Small Lakes*. Case: San Pedro Lagoons, Chile. Remote Sensing, v. 13, n. 22, p. 4544, 2021.

SANTOS, S. P. D. *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*. 2012. 131 f. - Universidade Federal de Minas Gerais, Belo Horizonte, 2012. Disponível em: [https://repositorio.ufmg.br/bitstream/1843/BUOS-92YPGV/1/disserta\\_\\_o\\_final\\_simone\\_santos.pdf](https://repositorio.ufmg.br/bitstream/1843/BUOS-92YPGV/1/disserta__o_final_simone_santos.pdf).

SHARAF, N. *et al. Lake surface temperature retrieval from Landsat-8 and retrospective analysis in Karaoun Reservoir, Lebanon*. Journal of Applied Remote Sensing, v. 13, n. 4, p. 044505, 2019.

SOUZA, B. T. A. e *et al. Temperatura superficial da água obtida por sensoriamento remoto em um reservatório tropical urbano*. In: Anais do XX Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis, 2023. Disponível em: <https://proceedings.science/sbsr-2023/trabalhos/temperatura-superficial-da-agua-obtida-por-sensoriamento-remoto-em-um-reservator?lang=pt-br>. Acesso em: 11 out. 2024.

USGS. *Landsat Satellite Missions*. EUA, 2020. Disponível em: <https://www.usgs.gov/landsat-missions/landsat-satellite-missions>. Acesso em: 7 abr. 2025.

VIEIRA, L. da C. *Uso integrado de modelagem matemática e sensoriamento remoto para compreensão da hidrodinâmica do reservatório Serra Azul/MG*. 2019. 188 f. Dissertação de mestrado. Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos - Universidade Federal de Minas Gerais, Belo Horizonte, 2019. Disponível em: <https://repositorio.ufmg.br/handle/1843/32382>. Acesso em: 11 out. 2024.

WERMUTH, L. *et al.* *Using landsat 8 images for monitoring surface water temperature in an urban tropical reservoir.* In: PROCEEDINGS OF THE 39TH IAHR WORLD CONGRESS FROM SNOW TO SEA, 2022. Proceedings of the 39th IAHR World Congress. Granada: International Association for Hydro-Environment Engineering and Research (IAHR), 2022. p. 5351–5358. Disponível em: <https://www.iahr.org/library/infor?pid=21390>. Acesso em: 11 out. 2024.