

Avaliação de redes neurais artificiais para a previsão da temperatura superficial da água em um reservatório urbano

Mariana S. Reis¹, Bruno M. Brentan², Nilo O. Nascimento³ & Talita F. G. Silva⁴

Resumo: A previsão da temperatura superficial da água de lagos é fundamental para o planejamento e a gestão de sistemas aquáticos. Embora modelos tradicionais sejam utilizados para esse fim, eles podem apresentar limitações na representação de relações não lineares complexas. Neste contexto, o objetivo deste trabalho foi avaliar o desempenho de redes neurais artificiais do tipo MLP na previsão da temperatura superficial da água em um reservatório urbano, considerando diferentes horizontes. A pesquisa foi realizada na Lagoa da Pampulha, em Belo Horizonte (MG), um ambiente urbanizado. Foram utilizados dados de temperatura superficial da água e variáveis meteorológicas em frequência horária. A metodologia incluiu pré-processamento dos dados (limpeza, integração e imputação), construção de variáveis auxiliares e treinamento de modelos MLP com diferentes configurações e horizontes de previsão (0 a 24 h), com validação cruzada. Os resultados indicaram bom desempenho geral, com $NSE > 0,9$, MAE e $RMSE < 0,7$ °C na validação. Modelos com maior número de variáveis meteorológicas (Grupo B) apresentaram desempenho ligeiramente superior, mas modelos mais simples (Grupo A) mostraram melhor relação custo-benefício. O desempenho foi melhor em previsões de curto prazo (até 3 h) e pior em horizontes intermediários (12 h). Na aplicação em um conjunto de dados distinto, o desempenho reduziu (NSE entre 0,7 e 0,8; $RMSE \sim 1,7$ °C), mas manteve consistência. O modelo MLP foi eficaz para previsão da temperatura da água, especialmente no curto prazo, embora apresente limitações na representação de extremos térmicos.

Abstract: The prediction of the lake surface water temperature is fundamental for the planning and management of aquatic systems. Although traditional models are used for this purpose, they may have limitations in the representation of complex nonlinear relationships. In this context, the objective was to evaluate the performance of artificial neural networks of the MLP type in predicting surface water temperature in an urban reservoir, considering different horizons. The study took place at Lagoa da Pampulha, located in Belo Horizonte (MG). Lake surface water temperature and hourly meteorological data were used. The methodology included data pre-processing (cleaning, integration, and imputation), construction of auxiliary variables and training of MLP models with different configurations and forecast horizons (0 to 24 h), with cross validation. The results indicated good overall performance, with $NSE > 0.9$, MAE and $RMSE < 0.7$ °C in validation. Models with a higher number of meteorological variables (Group B) showed slightly higher performance, but simpler models (Group A) showed a better cost-benefit ratio. The performance was better in short-term forecasts (up to 3 h) and worse in intermediate horizons (12 h). In applications, in a different dataset, performance decreased (NSE between 0.7 and 0.8; $RMSE \sim 1.7$ °C) but maintained consistency. The MLP model was effective for predicting water temperature, especially in the short term, although it has limitations in the representation of thermal extremes.

Palavras-Chave: Aprendizado de máquina, Lago, Modelagem Preditiva, Qualidade da Água

Keywords: Machine Learning, Lake, Predictive Modeling, Water Quality

1) Departamento de Engenharia Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais. (marianasdreis@gmail.com)

2) Departamento de Engenharia Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais. (brentan@ehr.ufmg.br)

3) Departamento de Engenharia Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais. (niloon@ehr.ufmg.br)

4) Departamento de Engenharia Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais. (talita.silva@ehr.ufmg.br)

INTRODUÇÃO

A temperatura superficial da água (TSA) de lagos e reservatórios constitui um fator de grande relevância, influenciando diretamente as características bioquímicas e físicas dos corpos hídricos, como a solubilidade de gases, as taxas de reações bioquímicas e a distribuição das espécies (Xu *et al.*, 2022; Wang *et al.*, 2024). Assim, informações sobre a temperatura da água são fundamentais para avaliar a qualidade hídrica e subsidiar ações de preservação e recuperação desses sistemas.

As trocas de calor que ocorrem na superfície de sistemas lânticos são fortemente influenciadas pelas variáveis meteorológicas, como a temperatura do ar, a radiação solar, a velocidade do vento e a umidade (Antonopoulos e Gioanniu, 2022). Em ambientes mais antropizados, a complexidade dessas interações aumenta, uma vez que a urbanização promove alterações no ciclo hidrológico local (Lemos *et al.*, 2014). As variáveis meteorológicas, no geral, são monitoradas com frequência diárias e subdiárias, o que disponibiliza uma base importante para o desenvolvimento de modelos capazes de estimar a temperatura da água.

Além das variáveis meteorológicas, o período do ano e a profundidade de interesse também são fatores relevantes, pois relacionam a dinâmica térmica do sistema à sazonalidade climática e aos processos de mistura e estratificação. Variáveis associadas à defasagem temporal também podem ser consideradas, uma vez que a temperatura da água não responde de forma imediata às variações atmosféricas. Devido à sua inércia térmica, essa resposta pode variar de horas a dias, dependendo das características do lago (Toffolon *et al.*, 2020).

O comportamento complexo e não linear desses fatores meteorológicos, juntamente com suas interações, representa um desafio para a previsão da temperatura superficial da água de lagos (Yang *et al.*, 2019). Recentemente, modelos não paramétricos baseados em técnicas de aprendizado de máquina têm ganhado destaque na modelagem desses processos. Entre essas abordagens, têm-se as redes neurais do tipo *MultiLayer Perceptron* (MLP), caracterizadas por uma arquitetura composta por múltiplas camadas e pelo uso de funções de ativação não lineares, o que possibilita a modelagem eficiente de relações complexas. No contexto da predição da TSA em lagos, a literatura concentra-se principalmente em simulações sem caráter preditivo ou em previsões com resoluções temporais diárias e mensais. (Antonopoulos e Gioanniu, 2022; Yousefi e Toffolon, 2022; Li *et al.*, 2024).

Em contraste, este trabalho adota uma abordagem com previsão em escala horária, explorando uma resolução temporal mais refinada. Assim, o objetivo é avaliar o desempenho de redes neurais artificiais do tipo MLP na previsão da temperatura superficial da água, considerando diferentes horizontes em um reservatório urbano: a Lagoa da Pampulha, em Belo Horizonte (MG).

MÉTODOS

Área de estudos

A área de estudo corresponde à Lagoa da Pampulha, localizada no município de Belo Horizonte, Minas Gerais (Figura 1). A bacia hidrográfica de contribuição desse reservatório é composta por 40 cursos d'água distribuídos em 8 sub-bacias, com área de drenagem de aproximadamente 97,6 km². O corpo hídrico tem volume igual a 9,44 hm³ e espelho d'água de 1,92 km², ao nível d'água normal, com elevação de 801 m (PAE Pampulha-PBH, 2021).

O clima é caracterizado por temperatura média de 22,1 °C, com temperatura mínima média mensal de 19,4 °C em julho e máxima média mensal de 24,0 °C em fevereiro, já a precipitação média anual é de 1578 mm, dados registrados no período entre 1991-2020 (INMET, 2020) com

invernos secos e verões chuvosos. A população da bacia, conforme o censo de 2022, é de 452.069 habitantes. Em termos de uso e ocupação do solo, cerca de 12,0% da área é composta por vegetação arbustiva e florestal, enquanto 75,4% correspondem à área urbanizada (Mapbiomas, 2023).




Figura 1 – Localização da Lagoa da Pampulha, da estação meteorológica e ponto de coleta aquático.

Aquisição dos dados observados

Os dados de temperatura da água da Lagoa da Pampulha observados *in situ* foram compilados a partir de coletas realizadas por diferentes projetos, todos financiados por agências de fomento e conduzidos na UFMG. São eles: o projeto Manejo de Águas Pluviais (MAPLU) com apoio da FINEP; e o projeto Modelagem de Mananciais Metropolitanos Estratégicos como Insumo para a Gestão de Água e Território Face à Mudança Climática (MoMa-se) financiado pela CAPES e ANA. Informações sobre o monitoramento realizado no âmbito desses projetos podem ser encontradas em Silva (2014), Belico (2017), Plec (2020).

Os dados de temperatura superficial da água coletados no ponto P2, localizado na região central da Lagoa da Pampulha (Figura 1, coordenadas 19° 51' 04" S e 43° 58' 36" O) foram utilizados para este estudo. O Quadro 1 apresenta as informações sobre esses dados.

Equipamento	Período de monitoramento	Frequência	Profundidade
STPS 35012 (nke, França)	02/2016 a 05/2017	30 min.	~ 0,1m
Boia SMATCH (nke, França)	2013, 2015 a 2016	horária	~ 0,8 m

Quadro 1 – Disponibilidade dos dados *in situ*.

Já os dados meteorológicos foram obtidos junto ao Instituto Nacional de Meteorologia (INMET) relativos à estação meteorológica automática mais próxima (estação Pampulha A521), a cerca de 3 km do Lago da Pampulha (Figura 1 coordenadas 19° 53' 02" S e 43° 58' 10" O). Os dados utilizados, em escala horária foram: precipitação total (mm), pressão atmosférica ao nível da estação (mb), temperatura do ar do bulbo seco (°C), umidade relativa do ar (%), direção (°), e velocidade do vento (m/s) e; a radiação global em W/m², convertida a partir da medida de toda radiação solar que incidente na superfície terrestre em 1 hora (Kj/m²).

Modelo MultiLayer Perceptron

Dados e pré-processamento

Para a aplicação do modelo foram utilizados dados meteorológicos como variáveis de entrada. A temperatura da água medida pela Boia SMATCH foi adotada como variável alvo nas etapas de treinamento e validação. Já os dados da sonda STPS 35012 foram empregados na fase de aplicação, permitindo testar e avaliar o desempenho do modelo já consolidado.

Além dos dados meteorológicos mencionados, quatro variáveis foram incluídas como entradas nos modelos. Duas delas visam caracterizar o comportamento recente da temperatura do ar: a média móvel dos três registros anteriores e a tendência, estimada pela diferença entre os dois registros anteriores. As outras duas variáveis relacionadas à sazonalidade anual, por meio da codificação cíclica do dia do ano, na qual o dia é projetado em uma representação circular utilizando as funções seno e cosseno, sendo o 1º dia do ano, 0 grau e 365º dia, 360 graus.

O pré-processamento desses dados incluiu limpeza, integração e imputação. A limpeza removeu inconsistências e definiu as janelas temporais de análise; a integração padronizou as séries para resolução horária por meio de médias. Para o preenchimento de falhas, utilizou-se interpolação linear nos dados meteorológicos (~0,2%) e KNN (K=5) nos dados de temperatura (~4%), gerando séries finais de 16.252 registros de 27/01/2015 a 04/12/2016 (SMATCH) e 7.062 registros de 29/12/2016 a 19/10/2017 (STPS).

Configurações do modelo

Com os dados devidamente preparados, os modelos de previsão foram desenvolvidos utilizando uma rede neural do tipo *Multilayer Perceptron* (MLP), implementada na biblioteca PyTorch. A arquitetura adotada consiste em uma rede *feedforward* com múltiplas camadas totalmente conectadas, incluindo camadas ocultas compostas por neurônios artificiais. Os modelos foram configurados para resolver um problema de regressão, com múltiplas variáveis de entrada e uma única variável de saída. Foram considerados horizontes de previsão (T) de 0, 1, 3, 6, 12 e 24 horas à frente. As variáveis de entrada são os dados meteorológicos e as quatro variáveis, enquanto a variável de saída corresponde à temperatura superficial da água da lagoa no instante T à frente.

Foram utilizadas funções de ativação ReLU e, em redes mais profundas, *dropout*. Os dados foram normalizados utilizando o método *StandardScaler* e divididos em treino e validação, com avaliação por validação cruzada *k-fold* (k=5, 80% treino e 20% validação) com a variável alvo sendo a TSA da Boia SMATCH. O modelo foi treinado com o otimizador Adam e função de perda é erro quadrático médio (MSE). A melhor arquitetura foi definida por Grid Search, testando até três camadas ocultas e 128 neurônios, com seleção baseada no maior valor médio de eficiência de Nash-Sutcliffe (NSE).

Após a identificação da melhor configuração, o modelo final foi treinado e em seguida, foi aplicado a todo o conjunto de dados para geração das previsões, que foram comparadas aos valores observados. O desempenho de cada modelo foi avaliado por meio de um conjunto de métricas, incluindo NSE, MSE, erro absoluto médio (MAE), raiz do erro quadrático médio (RMSE).

As diferentes combinações de variáveis de entrada foram organizadas em cenários, estruturados em dois grupos distintos: Grupo A - Temperatura do ar (T_{ar}); média móvel da T_{ar} ; tendência da T_{ar} ; Duas variáveis da posição cíclica do dia do ano, seno e cosseno; Grupo B - Todas as variáveis meteorológicas; média móvel da T_{ar} ; tendência da T_{ar} ; Duas variáveis da posição cíclica do dia do ano, seno e cosseno.

RESULTADOS E DISCUSSÃO

Modelo *MultiLayer Perceptron*

A Tabela 1 reúne as métricas de desempenho obtidas para os 12 cenários avaliados, considerando os dois grupos de variáveis de entrada e os diferentes horizontes de previsão. Esses resultados permitem comparar o desempenho dos modelos em função das combinações adotadas.

Conjuntos de Variáveis de entrada	Cenários	Melhor Arquitetura	Validação Cruzada				Modelo Final			
			NSE	MAE (°C)	RMSE (°C)	MSE (°C²)	NSE	MAE (°C)	RMSE (°C)	MSE (°C²)
GRUPO A: T_{ar} ; média móvel da T_{ar} ; tendência da T_{ar} ; Par seno e cosseno da posição cíclica do dia do ano	A_T0	[128, 64, 32]	0.938	0.452	0.599	0.359	0.947	0.416	0.551	0.304
	A_T1	[64, 64, 32]	0.940	0.444	0.588	0.346	0.946	0.424	0.559	0.312
	A_T3	[64, 64, 32]	0.942	0.436	0.577	0.333	0.946	0.423	0.556	0.310
	A_T6	[128, 64, 32]	0.938	0.453	0.598	0.358	0.944	0.428	0.565	0.319
	A_T12	[64, 64, 32]	0.920	0.506	0.677	0.459	0.924	0.492	0.662	0.438
	A_T24	[128, 64, 32]	0.937	0.446	0.600	0.360	0.945	0.421	0.560	0.314
GRUPO B: Variáveis meteorológicas; média móvel da T_{ar} ; tendência da T_{ar} ; Par seno e cosseno da posição cíclica do dia do ano	B_T0	[64, 64, 32]	0.957	0.369	0.498	0.248	0.969	0.314	0.421	0.177
	B_T1	[128, 64, 32]	0.958	0.358	0.490	0.240	0.973	0.297	0.398	0.158
	B_T3	[64, 64, 32]	0.956	0.368	0.500	0.250	0.970	0.307	0.418	0.175
	B_T6	[128, 64, 32]	0.951	0.386	0.530	0.280	0.967	0.318	0.433	0.187
	B_T12	[128, 64, 32]	0.940	0.424	0.586	0.343	0.958	0.361	0.494	0.244
	B_T24	[64, 64, 32]	0.950	0.391	0.535	0.286	0.965	0.328	0.447	0.199

Tabela 1 – Métricas de desempenho dos modelos MLP.

Em relação à arquitetura, todos os cenários apresentaram resultados melhores com estruturas de três camadas, em comparação às de duas camadas, destacando-se configurações com maior número de neurônios (1ª camada oculta com 128 ou 64), o que sugere maior eficiência em capturar a variabilidade da temperatura da água em estruturas mais complexas. Quanto às métricas, os modelos apresentaram bom desempenho, com valores de NSE superiores a 0,9, MAE e RMSE inferiores a 0,7 °C e MSE inferiores a 0,5 °C².

Observa-se uma variação relativamente pequena entre horizontes de previsão entre T0 e T3, indicando estabilidade no desempenho para previsões de curto prazo. A partir de T6, há uma degradação mais evidente das métricas, com o pior desempenho sendo registrado no horizonte T12. Essa degradação do desempenho em T12 pode estar associada ao acúmulo de incertezas na propagação temporal das variáveis de entrada, além da perda de correlação direta entre temperatura do ar e temperatura da água em horizontes intermediários.

Em seguida, nota-se uma melhora no desempenho em T24, o que pode indicar a influência da periodicidade diária, sugerindo que o modelo consegue capturar padrões associados ao ciclo diurno. Assim, os melhores resultados concentram-se nos horizontes mais curtos (T0 a T3), enquanto o horizonte T12 apresenta o desempenho mais limitado entre os cenários avaliados.

Os resultados obtidos neste estudo, com NSE superiores a 0,9 e RMSE inferiores a 0,7 °C para previsões horárias, indicam desempenho superior ou comparável ao reportado na literatura para previsões instantâneas, como em Yousefi e Toffolon (2022) e Belouz *et al.* (2025), que apresentam RMSE acima de 1 °C. Esse ganho pode estar associado à alta resolução temporal dos dados (horária), que favorece a captura da variabilidade da TSA. Em consonância com Di *et al.* (2023), observou-se degradação do desempenho com o aumento do horizonte de previsão, refletindo a maior dificuldade em representar a dinâmica térmica futura e, especialmente, os picos de temperatura.

Ao comparar os grupos de variáveis, verifica-se que o Grupo B tende a apresentar melhor desempenho, especialmente em condições de temperaturas mais elevadas (Figura 2), em relação ao

Grupo A, com ganhos de aproximadamente 3% na métrica NSE. No entanto, considerando o menor número de variáveis de entrada e, conseqüentemente, o menor custo computacional, os modelos do Grupo A demonstram maior eficiência com relação a desempenho-complexidade.

Cabe ressaltar que esses modelos apresentam vantagens distintas em termos de interpretação e aplicabilidade, a depender do objetivo: os modelos do Grupo A são mais parcimoniosos, enquanto os do Grupo B podem ser mais eficientes na previsão de temperatura da água durante ondas de calor, por exemplo. Nesse contexto, a Figura 2 apresenta os gráficos de dispersão dos modelos A_T3, A_T12, B_T3 e B_T12, permitindo uma análise visual comparativa de seus desempenhos.




Figura 2 – Temperatura superficial da água observada e prevista nos cenários A_T3, A_T12 e B_T3 e A_T12 (roxo) e reta 1:1 (verde).

Observa-se na Figura 2 que o cenário A_T12 apresenta maior dispersão, em concordância com as métricas de desempenho. De modo geral, os modelos apresentam melhor ajuste na faixa entre 20 e 25°C, onde os pontos estão mais aderidos à reta 1:1, indicando menor erro. Para valores superiores a 29°C, verifica-se uma tendência sistemática de subestimação da temperatura da água, possivelmente associada à menor representatividade de dados nessa faixa.

A subestimação sistemática para temperaturas acima de 29 °C pode estar associada à baixa representatividade desses eventos no conjunto de treinamento, levando o modelo a prever valores mais próximos à média. Tal comportamento é menos pronunciado no Grupo B, indicando que a inclusão de variáveis meteorológicas adicionais, além da temperatura do ar, contribui para uma melhor representação de temperaturas mais elevadas.

Essa subestimação em temperaturas elevadas também corrobora achados prévios, indicando limitação recorrente de modelos de aprendizado de máquina na representação de extremos. Por outro lado, diferentemente de estudos em escala mensal e cenários futuros, como Li *et al.* (2024), este trabalho foca na previsão horária, o que reforça sua aplicabilidade operacional, embora limite as inferências sobre tendências climáticas de longo prazo.

Nota-se também um aumento da dispersão dos pontos com o aumento da temperatura, evidenciando maior incerteza nas previsões em valores elevados (Figura 2). A comparação entre os horizontes de previsão mostra que os modelos em T3 apresentam menor dispersão em relação aos de T12, ilustrando a diminuição do desempenho para horizontes mais longos. Por fim, os modelos do Grupo B apresentam, no geral, maior concentração dos pontos em torno da reta 1:1, indicando melhor desempenho em relação ao Grupo A.

A influência das variáveis de entrada observadas neste estudo está alinhada com a literatura, que aponta a temperatura do ar como principal preditora da temperatura da água. Assim como em Belouz *et al.* (2025), verificou-se que a inclusão de variáveis sazonais, como o dia do ano, contribui para a melhoria do desempenho dos modelos, ainda que de forma moderada. O melhor desempenho

do Grupo B indica que a incorporação de múltiplas variáveis meteorológicas permite capturar processos físicos mais complexos, conforme também sugerido por estudos como Li *et al.* (2024). No entanto, os bons resultados obtidos com o Grupo A reforçam que modelos mais simples, baseados na temperatura do ar e variáveis derivadas, podem a depender do objetivo ser suficientes para previsões de curto prazo.

Aplicação do modelo *MultiLayer Perceptron*

Os modelos foram testados e avaliados com dados de temperatura da água distintos daqueles usados em sua construção, empregando medições da sonda STPS no mesmo ponto (P2), porém com profundidade de 0,1 m, o que permite um vislumbre da aplicação. Os modelos utilizados foram os com horizonte de previsão de 3h e 12h, para ilustrar os com melhor e pior desempenho, respectivamente, para ambos os conjuntos de variáveis, Grupo A e Grupo B. A Tabela 2 mostra as métricas de desempenho obtidas e a Figura 3 o gráfico de dispersão dos modelos.

Conjuntos de Variáveis de entrada	Cenário	NSE	MAE (°C)	RMSE (°C)	MSE (°C²)
GRUPO A	A_T3	0.755	1.404	1.729	2.988
	A_T12	0.754	1.442	1.781	3.171
GRUPO B	B_T3	0.775	1.341	1.654	2.735
	B_T12	0.783	1.359	1.675	2.804




Tabela 2 – Métricas dos modelos MLP aplicados.

Figura 3 – Temperatura superficial da água observada e prevista da aplicação nos cenários A_T3, A_12 (azul) e B_T3 e A_T12 (laranja) e reta 1:1 (verde).

Em relação aos resultados, observa-se na Tabela 2 que os modelos tiveram um desempenho consistente na aplicação, com valores de NSE entre 0,7 e 0,8, mesmo que inferior aos resultados da Tabela 1, indicando capacidade de representação adequada, o que é esperado devido à diferença de profundidade entre a sonda STPS e a Boia SMATCH. Os erros com MAE próximo de 1,4 °C e RMSE em torno de 1,7 °C e o MSE variando mais, indicando a presença de erros maiores, que são mais penalizados pela métrica quadrática.

Destaca-se que o melhor desempenho permanece nas previsões de curto prazo ($T = 3$ h), possivelmente associado à influência das variáveis temporais empregadas, evidenciando a capacidade dos modelos em capturar a dinâmica mais imediata do sistema. Para horizontes de previsão mais longos ($T = 12$ h), observa-se uma leve redução no desempenho, como esperado, mas ainda com resultados que indicam potencial de aplicação dos modelos.

Em relação à Figura 3, cabe destacar que o desempenho observado na porção inferior do gráfico pode estar relacionado às diferenças entre os dados de treinamento e de aplicação. O modelo foi treinado com medidas a 0,8 m de profundidade, enquanto os dados de aplicação correspondem à camada mais superficial ($\sim 0,1$ m), mais diretamente influenciada por forçantes atmosféricas e, portanto, sujeita a maior variabilidade térmica e ocorrência de valores extremos. Assim, o treinamento foi realizado com dados na faixa de 19 °C a 32 °C, enquanto o conjunto aplicado inclui valores inferiores a 19 °C, ou seja, fora do domínio de treinamento. Nessas condições, a capacidade de generalização do modelo foi reduzida. Esse descompasso pode explicar a tendência de superestimação dos valores de temperatura na faixa de 15 a 21 °C.

Para temperaturas superiores a essa faixa, observa-se maior aderência dos pontos à reta 1:1, indicando melhor desempenho do modelo dentro do domínio de treinamento. Desse modo, o efeito de subestimação previamente identificado para temperaturas acima de 29 °C ainda se mantém, mas nesse caso é semelhante entre os grupos, sugerindo dificuldade na previsão valores mais elevados.

CONCLUSÃO

No presente trabalho, foi aplicado um modelo MLP capaz de prever a temperatura superficial da água da Lagoa da Pampulha, com desempenho satisfatório. Observou-se maior precisão em previsões de curto prazo (até 3 h), evidenciando a capacidade do modelo em captar a dinâmica imediata do sistema. Ajustes nas variáveis de entrada como, a adequação da média móvel da temperatura do ar ao horizonte de previsão, podem aprimorar os resultados. Ainda assim, há limitações na representação de extremos térmicos. Nesse sentido, recomenda-se o uso de dados com maior variabilidade térmica, bem como a exploração de outras abordagens como o aprendizado de máquina fisicamente informado.

AGRADECIMENTOS

Os autores agradecem às agências de fomento FAPEMIG, CAPES e CNPq pelas bolsas concedidas a todos os autores deste artigo.

REFERÊNCIAS

- ANTONOPOULOS, V. Z.; GIOANNIOU, S. K. (2022). *Analysis and Modelling of Temperature at the Water-Atmosphere Interface of a Lake by Energy Budget and ANNs Models*. Environmental Processes, 9, 15.
- BELICO, J. (2017). *Impactos de eventos chuvosos na dinâmica físico-química e biológica em reservatórios urbanos*. (Dissertação de Mestrado). Universidade Paris-Est, Universidade Federal de Minas Gerais, França.
- BELOUZ, K.; ZEREG, S.; MATAALLAH, S. (2025). *Modeling reservoir surface water temperature with neural networks and ANFIS insights from sensitivity analysis*. Larhyss Journal, 64, 57.
- DI NUNNO, F.; ZHU, S.; PTAK, M.; SOJKA, M.; GRANATA, F. (2023). *A stacked machine learning model for multi-step ahead prediction of lake surface water temperature*. Science of the Total Environment, 890, 164323.
- LEMOES, R.S.; FERREIRA, R.; CARVALHO, V. L. M.; MAGALHÃES JUNIOR, A. P.; LOPES, F. (2014). *A evolução do uso e ocupação em uma bacia hidrográfica urbana e suas consequências para a qualidade ambiental: reflexões a partir do caso da Lagoa da Pampulha*. Anais do Seminário Nacional sobre o Tratamento de Áreas de Preservação Permanente em Meio Urbano. Belém.
- LI, Z.; ZHANG, Z.; XIONG, S.; ZHANG, W.; LI, R. (2024). *Lake Surface Temperature Predictions under Different Climate Scenarios with Machine Learning Methods: A Case Study of Qinghai Lake and Hulun Lake, China*. Remote Sensing, 16(17), 3220.
- MAPBIOMAS. (2023) *Coleção 9 - Série Anual de Mapas de Cobertura e Uso do Solo do Brasil*. MapBiomias.
- PLEC, D. (2020) *Influence of hydrodynamics on phytoplankton behaviour in lakes in urban areas through high-frequency measurements and three-dimensional numerical modelling: Application to lake champs-sur-marne (France) and lake Pampulha (Brazil)*. (Tese de Doutorado). Universidade Federal de Minas Gerais, Belo Horizonte.
- PREFEITURA DE BELO HORIZONTE. (2021). *Plano de Ação e Emergência da Barragem da Pampulha*. UFMG/FCO.
- SILVA, T. (2014). *Suivi et modélisation de la dynamique des cyanobactéries dans les lacs urbains au sein de leur bassin versant*. (Tese de Doutorado). Universidade Paris-Est, Universidade Federal de Minas Gerais, França.
- TOFFOLON, M.; PICCOLROAZ, S.; CALAMITA, E. (2020). *On the use of averaged indicators to assess lakes' thermal response to changes in climatic conditions*. Environmental Research Letters, 15(3), 034060.
- WANG, W.; SHI, K.; WANG, X.; ZHANG, Y.; QIN, B.; ZHANG, Y.; WOOLWAY, R.I. (2024). *The impact of extreme heat on lake warming in China*. Nat. Commun, 15, 70.
- YANG, K.; YU, Z.; LUO, Y.; ZHOU, X.; SHANG, C. (2019). *Spatial-Temporal Variation of Lake Surface Water Temperature and Its Driving Factors in Yunnan-Guizhou Plateau*. Water Resour. Res. 55, 4688–4703.
- YOUSEFI, E.; TOFFOLON, M. (2021). *Critical factors for the use of machine learning to predict lake surface water temperature*. Journal of Hydrology. 606, 127418.