



DESEMPENHO DA PSO NO AJUSTE DE MODELO DE ESTIMATIVA DE TEMPERATURA DE ÁGUA EM LAGOA RASA COSTEIRA SUBTROPICAL

Carlos Henrique Saldanha Ferrari¹, Matheus Henrique Tavares², Lúcia Helena Ribeiro Rodrigues¹, David da Motta Marques¹ & Juan Martín Bravo¹

Resumo: A temperatura da água é determinante de processos físicos, químicos e biológicos em lagos. Dada a escassez de dados *in situ* de temperatura da água, alternativas como a modelagem da qualidade da água vêm sendo implementadas para estimar este importante parâmetro do ponto de vista limnológico. Entre elas, destaca-se o modelo de estimativa de temperatura da água *Air2Water*, aplicado inicialmente junto ao Lago Superior, o mais profundo e o de maior área superficial entre os Grandes Lagos da América do Norte. Nesse cenário, o objetivo deste trabalho foi avaliar o ajuste do modelo *Air2Water* à Lagoa Mangueira, ecossistema localizado no Extremo Sul do Brasil e configurado como raso, costeiro, subtropical e polimítico. O método de otimização mono-objetivo acoplado ao modelo *Air2Water* utilizado em sua etapa de ajuste foi a otimização por enxame de partículas - do inglês, Particle Swarm Optimization (PSO), cujo desempenho, mensurado pelas funções-objetivo coeficiente de *Nash-Sutcliffe* (NSE) e pela raiz do erro quadrático médio (RMSE), mostrou-se muito satisfatório no ajuste da versão de 8 parâmetros do modelo *Air2Water* à Lagoa Mangueira. Foram obtidos NSE = 0,96 e RMSE = 0,85°C para o período de calibração, e NSE = 0,95 e RMSE = 0,95°C para o período de verificação. Foi observada ainda a manutenção dos valores de NSE e RMSE mesmo com a redução do número de partículas utilizadas na PSO, indicando que não há comprometimento de desempenho do ajuste do modelo *Air2Water*. A redução da quantidade de partículas da PSO de 1000 para 100 representou um tempo médio de execução do processo de ajuste do modelo *Air2Water* oito vezes menor, com tal ganho computacional reforçando o potencial de aplicação dessa ferramenta em estudos limnológicos e de modelagem da qualidade da água.

Palavras-Chave: Lagos; temperatura da água; modelagem; PSO; ganho computacional.

Abstract: Water temperature drives physical, chemical and biological processes in lakes. Given the scarcity of *in situ* water temperature data, alternatives such as water quality modeling are used to estimate this critical parameter from a limnological point of view. One is the water temperature estimation model *Air2Water*, initially applied to Lake Superior, North America's deepest and largest surface area of the Great Lakes. In this sense, this study aimed to assess the performance of the *Air2Water* model in Lake Mangueira, an ecosystem located in the southmost part of Brazil and configured as shallow, coastal, subtropical and polimitic. The mono-objective optimization method used in adjustment the *Air2Water* model was Particle Swarm Optimization (PSO). The performance of PSO, measured by the NSE (Nash-Sutcliffe Efficiency) and RMSE (Root-mean square error) objective functions, proved to be very satisfactory in adjusting the 8-parameter version of the *Air2Water* model to the Lake Mangueira, with NSE = 0.96 and RMSE = 0.85°C for the calibration period, and NSE = 0.95 and RMSE = 0.95°C for the verification period. We also found maintenance of the NSE and RMSE values even when the number of particles used in the PSO was reduced, indicating that the *Air2Water* model adjustment performance is not compromised. Reducing the number of PSO particles from 1000 to 100 represented an eight-fold reduction in the average execution time of the *Air2Water* model adjustment process, with this computational gain reinforcing the application potential of this tool in limnological and water quality modeling studies.

Keywords: Lake; water temperature; modeling; PSO; computational gain.

1) Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 9500, Agronomia, Porto Alegre, Rio Grande do Sul, Brasil, 91501-970, telefone: (51) 3308-6680, e-mail: carlosh.sferrari@gmail.com e jumarbra@iph.ufrgs.br

2) Institut de Recherche pour le Développement, France



INTRODUÇÃO

Embora estejam associados a importantes serviços ambientais, lagos representam apenas 0,26% do total de água doce na Terra (Collischonn e Dornelles, 2015). Pressionados nessa ótica quantitativa, tais ecossistemas encontram-se em constante condição de vulnerabilidade, reforçada pelos efeitos da atividade humana, como a poluição hídrica. Dessa forma, é necessário um adequado monitoramento das suas condições qualitativas, por meio de parâmetros que expressam suas características físicas, químicas e/ou biológicas (Barbosa *et al.* 2019). Entre os parâmetros tipicamente utilizados para monitor lagos, neste estudo será dada ênfase à temperatura, que rege processos físicos, químicos e biológicos nesses ecossistemas (Cavalcanti *et al.* 2016).

Apesar da importância da temperatura da água para o monitoramento de lagos, é dificultosa a obtenção de dados medidos *in situ* associados a este parâmetro. Entre as causas, a complexa operação de estações capazes de medir a temperatura da água desses ecossistemas (Handcock *et al.* 2012), além do difícil acesso aos locais de coleta (Guo *et al.* 2022). Para contornar a escassez de dados de temperatura da água medidos *in situ* (Tavares *et al.* 2019a), vêm sendo crescentes as aplicações de modelos de estimativa da temperatura da água, como o *Air2Water*, cuja única variável de entrada é a temperatura do ar, parâmetro de mais fácil obtenção e considerado principal regulador da troca de calor junto à superfície de lagos (Livingstone e Padisák, 2007).

O modelo *Air2Water* já foi validado na estimativa da temperatura da água de lagos do Planalto Tibetano (Guo *et al.* 2022), da China (Wang *et al.* 2024), ou mesmo com o Lago Superior, área de estudo avaliada em seu artigo de apresentação (Piccolroaz *et al.* 2013). No presente estudo, o objetivo é avaliar o ajuste do modelo *Air2Water* à Lagoa Mangueira, ecossistema localizado no Extremo Sul do Brasil, configurado como raso, costeiro, subtropical e polimítico, distinguindo-se, portanto, da morfometria do Lago Superior, o lago mais profundo e o de maior área superficial entre os Grandes Lagos da América do Norte (Piccolroaz, 2016). A otimização por enxame de partículas, ou *Particle Swarm Optimization* (PSO), foi o método de otimização acoplado por Piccolroaz *et al.* (2013) ao modelo *Air2Water*, e cujo desempenho foi mensurado pelas funções-objetivo coeficiente de *Nash-Sutcliffe* (NSE) e raiz quadrática do erro médio (RMSE), sendo utilizada uma por vez no processo de ajuste. Assim, verificou-se i) o ajuste do modelo *Air2Water* à Lagoa Mangueira e ii) a possibilidade de redução do número de partículas da PSO neste processo sem comprometimento de desempenho.

MÉTODOS

Área de estudo

A Lagoa Mangueira (Figura 1) está localizada na planície costeira do Rio Grande do Sul (RS), Brasil, próximo à fronteira com o Uruguai. A lagoa faz parte do Sistema Hidrológico do Taim, que abriga uma unidade de conservação federal, a Estação Ecológica do Taim (ESEC Taim com 33.935ha), e está situada em uma estreita faixa de terra entre o Oceano Atlântico e a Lagoa Mirim. Localizada entre 32°20' a 33°00' S e 52°20' a 52°45' W, a Lagoa Mangueira está em uma região subtropical com clima Cfa de acordo com a Classificação Climática de Köppen (Tavares *et al.* 2019a).

A Lagoa Mangueira é classificada como polimítica quente contínua, estratificando-se no máximo algumas horas de cada vez (Lewis Jr., 1983). Sua profundidade média é de 2,6 m e atinge uma profundidade máxima de 6,0 m na região central. A Lagoa Mangueira tem um comprimento de 90 km, uma área de superfície de 820 km², e sua largura varia de 3 a 10 km (Wieliczko *et al.* 2021). Na Figura 1, também é ilustrada a estação meteorológica Santa Vitória do Palmar, a partir da qual os dados diários de temperatura do ar foram obtidos.

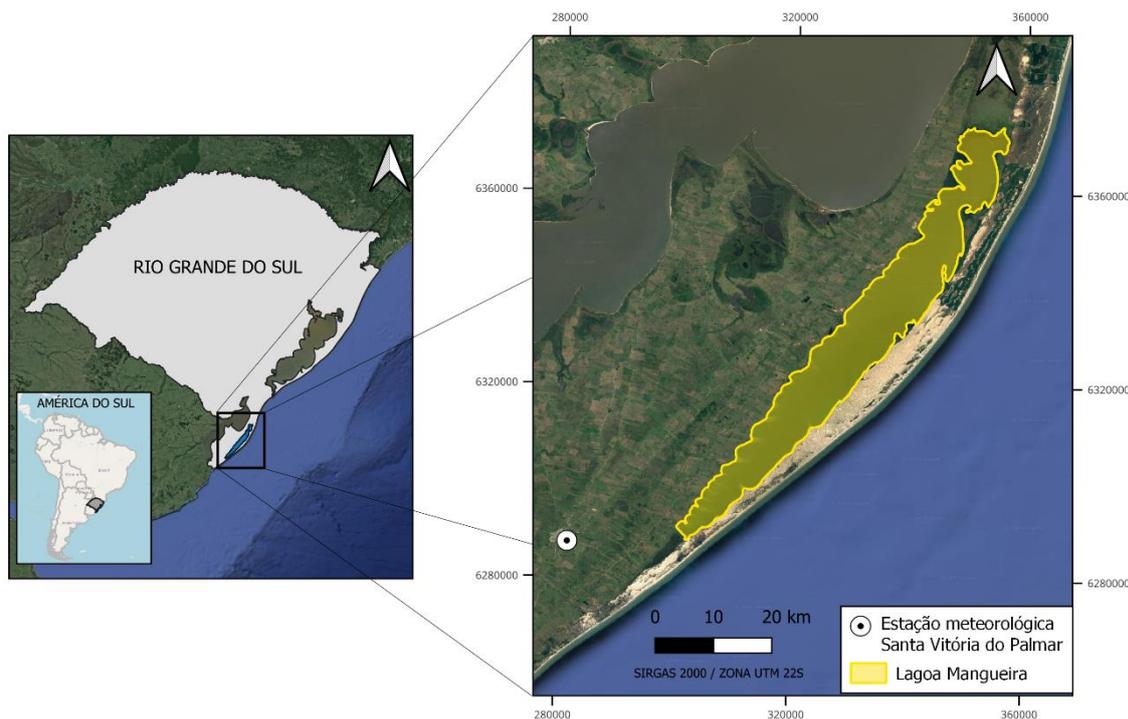


Figura 1 – Localização da Lagoa Mangueira e da estação meteorológica Santa Vitória do Palmar, RS.

Ajuste do modelo *Air2Water*

Proposto como um modelo simples de base física, o *Air2Water* associa a temperatura do ar à temperatura da água do epilímnio, camada superficial dos lagos. Os dados de entrada estão associados apenas à temperatura do ar, que troca calor com o epilímnio. Assim, o principal regulador da dinâmica térmica dos lagos no modelo *Air2Water* é a temperatura do ar, variável mais facilmente disponível que a temperatura da água (Tavares *et al.* 2019a). Essas são as duas variáveis utilizadas para ajuste do modelo *Air2Water*, que considera o lago como um sistema pontual (Piccolroaz *et al.* 2013). Entre as versões do modelo *Air2Water*, no presente estudo foi ajustada a versão completa, de 8 parâmetros, que têm significado físico detalhado abaixo na Tabela 2.

Parâmetros	Significado físico
a ₁	Diferença residual entre a temperatura do ar e a temperatura superficial do lago
a ₂	Associado à temperatura do ar e à sua diferença frente à temperatura da água
a ₃	Associado à temperatura da água e à sua diferença frente à temperatura do ar
a ₄	Associado à força de estratificação termal direta
a ₅	Amplitude do termo sinusoidal imposto externamente
a ₆	Fase do termo sinusoidal imposto externamente
a ₇	Associado à força de estratificação termal inversa
a ₈	Redução do fluxo de calor no período de cobertura do gelo

Tabela 2 - Significado físico dos parâmetros do modelo *Air2Water*. Adaptada de Toffolon *et al.* (2014).



Para ajuste do modelo *Air2Water*, mais de 20 anos de dados diários de temperatura superficial da água foram obtidos por sensoriamento remoto utilizando o sensor térmico *Moderate Resolution Imaging Spectroradiometer* (MODIS). O modelo *Air2Water* foi calibrado com dados de temperatura superficial da água de 2010 a 2019, em razão do maior percentual de dados válidos (36,45%) frente ao período de 2000 e 2009 (33,89%), utilizada para verificação do ajuste do modelo *Air2Water*. Já as séries temporais diárias de temperatura do ar foram obtidas da estação meteorológica de Santa Vitória do Palmar (Figura 1), que possui registros desde 1961. Entre 2010 e 2019, todos os dados diários de temperatura do ar eram válidos, ao passo que 99,99% dos dados eram válidos no período entre 2000 e 2009 (único dado faltante estimado por interpolação linear entre os valores dos dias adjacentes).

O produto Land Surface Temperature/Emissivity Daily Version 6.1 (MOD11A1v061), utilizado para obtenção dos dados diários de temperatura superficial da água via sensoriamento remoto, possui um tamanho de *pixel* de 1 km (Wan *et al.* 2021). Assim, o polígono que delimita a Lagoa Mangueira foi reduzido 1 km em direção ao seu interior para remover possíveis efeitos de *pixels* de porções de terra adjacentes ao lago. Este procedimento visa a evitar a contaminação com *pixels* que não são puramente água, e já foi aplicado em outros estudos que utilizaram dados de temperatura da superfície da água do MOD11A1v061 para (i.e. Guo *et al.* 2022).

Outro procedimento admitido para os dados de temperatura de superfície do MOD11A1v061 diz respeito ao efeito de pele fria, que pode ocorrer no monitoramento da água por sensoriamento remoto. Os sensores de satélite que operam na banda do infravermelho termal obtêm valores de temperatura da camada subsuperficial da água, que pode ter uma temperatura 0,1 a 0,5°C inferior à medida na coluna de água devido ao calor perdido para o ar no processo de evaporação (Handcock *et al.* 2012). Neste estudo, foi corrigido o viés de subestimação dos dados de temperatura superficial da água do MOD11A1v061 segundo os procedimentos apresentados por Tavares (2023).

Para garantir consistência no ajuste do modelo *Air2Water*, os dados de temperatura superficial da água foram filtrados com base numa contagem de *pixels* válidos. Para que uma imagem diária de temperatura superficial da água fosse incluída na série temporal, era necessário que pelo menos 30% dos *pixels* dentro do polígono da Lagoa Mangueira fossem válidos. Dada a existência de uma banda diurna e noturna do MOD11A1v061, apenas foram utilizados os dias em que as imagens de ambas as bandas tinham uma porcentagem de *pixels* válidos igual ou superior a 30%. Assim, a média entre os dados de temperatura superficial diurna e noturna formou a série de temperatura superficial da água usada para ajustar o modelo *Air2Water*, considerando toda a superfície da Lagoa Mangueira.

O método de otimização mono-objetivo acoplado por Piccolroaz *et al.* (2013) ao modelo *Air2Water* é a otimização por enxame de partículas, ou *Particle Swarm Optimization* (PSO). Dessa forma, a PSO determina os valores otimizados dos parâmetros do modelo *Air2Water* em sua etapa de ajuste. Um dos princípios da PSO é o aprendizado coletivo entre cada partícula do “enxame”, que compartilham informações em busca do ótimo global e configuram-se como soluções candidatas no espaço de busca. Matematicamente, o princípio de aprendizado coletivo está associado ao coeficiente c_2 , enquanto o coeficiente c_1 representa a memória própria de cada partícula deslocando-se com uma dada velocidade em cada iteração (Equação 1). Ambos os coeficientes foram fixados em 2 no presente estudo, valor que lhes é tipicamente atribuído (Kennedy e Eberhart, 1995).

$$V_{t+1} = w * V_t + c_1 * r_1 * (X_{best(t)} - X_{(t)}) + c_2 * r_2 * (G_{best(t)} - X_{(t)}) \quad (1)$$

Em que:

$V_{(t+1)}$ = velocidade da partícula na nova iteração [comprimento/tempo];

$V_{(t)}$ = velocidade da partícula na iteração anterior [comprimento/ tempo];

w = coeficiente de inércia, entre 0,4 e 0,9 (adimensional);



c_1 e c_2 : coeficientes de aprendizado, respectivamente, individual e coletivo [comprimento/tempo²];

r_1 e r_2 : números aleatórios com distribuição uniforme U [0,1];

$X_{best(t)}$ = melhor posição da partícula até a iteração anterior [comprimento];

$X_{(t)}$ = posição da partícula na iteração anterior [comprimento/tempo];

$G_{best(t)}$ = melhor posição entre as partículas do enxame até a iteração anterior [comprimento].

Outro parâmetro da PSO é a quantidade de partículas que participam do processo de ajuste do modelo *Air2Water*, cuja precisão em estimar a temperatura da água da Lagoa Mangueira foi avaliada como um dos objetivos deste estudo. Outro objetivo foi verificar o efeito da redução de 1000 pra 100 partículas da PSO no desempenho do processo de ajuste do modelo *Air2Water*, já assumindo que o valor *default* de 2000 pode ser reduzido sem comprometimento de desempenho (Saldanha-Ferrari et al. 2023). Para ambos os objetivos, o coeficiente de *Nash–Sutcliffe* (NSE) e a raiz do erro quadrático médio (RMSE) foram utilizadas como função-objetivo, uma por vez. Para cada função-objetivo e combinação de número de partículas, o processo de ajuste do modelo *Air2Water* foi repetido 3 vezes, totalizando 12 processos (2 funções objetivo \times 2 combinações de número de partículas \times 3 repetições). Os procedimentos de ajuste buscaram maximizar o NSE (valor máximo igual a 1) e minimizar a RMSE (valor mínimo igual a 0), e foram executados num computador com 2 processadores Intel(R) Xeon(R) CPU E5-2697 v3 @ 2.60 GHz.

RESULTADOS E DISCUSSÃO

No ajuste do modelo *Air2Water* à Lagoa Mangueira, obteve-se valores médios de NSE iguais a 0,96 (calibração) e 0,95 (verificação). Assim, dados os valores de NSE superiores a 0,75 (Motovilov et al. 1999), o modelo *Air2Water* estimou acuradamente a temperatura superficial da água da Lagoa Mangueira. Quanto aos valores médios de RMSE, iguais a 0,85°C (calibração) e 0,95°C (verificação), o ajuste do modelo *Air2Water* se mostrou superior ao obtido em sua primeira aplicação junto ao Lago Superior com a mesma versão do modelo e usando também dados de temperatura superficial da água obtidos via sensoriamento remoto (Piccolroaz et al. 2013). A título de ilustração, as séries temporais diárias de temperatura superficial da água observadas a partir de satélites e as simuladas a partir do modelo *Air2Water* são apresentadas nas Figuras 2 e 3.

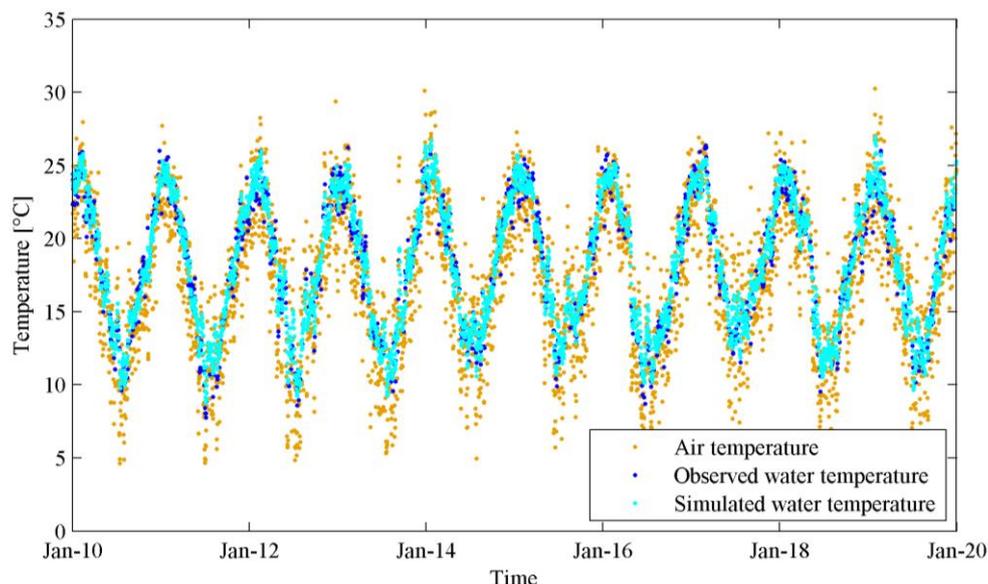


Figura 2 – Resultados do período de calibração da versão de oito parâmetros do modelo *Air2Water*.

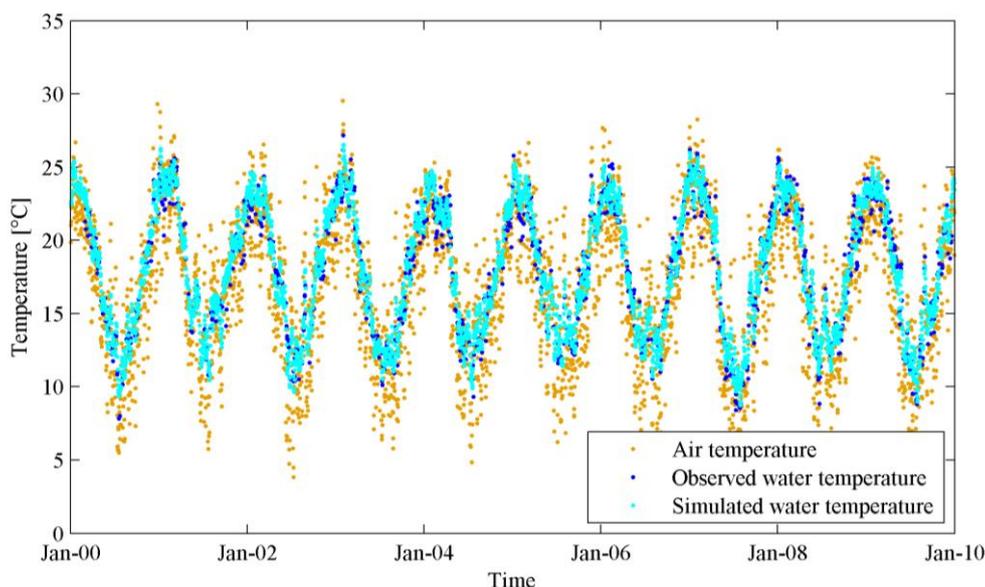


Figura 3 – Resultados do período de verificação da versão de oito parâmetros do modelo *Air2Water*.

A série temporal diária simulada pelo modelo *Air2Water* indica uma pequena superestimativa dos valores mínimos de temperatura superficial da água observados a partir de satélites, além de uma pequena subestimativa dos valores máximos (Figuras 2 e 3). Tal comportamento já fora observado na Lagoa Mangueira em aplicação do modelo *Air2Water* para avaliação de tendências de temperatura do ar e da água (Tavares et al. 2019b) e também no Lago Superior (Saldanha-Ferrari et al. 2023). Embora esse padrão possa se configurar como uma limitação do modelo *Air2Water*, destaca-se o seu bom desempenho na estimativa da temperatura da água de lagos de diferentes morfometrias. Na Lagoa Mangueira, de dinâmica térmica fortemente influenciada pela severa ação do vento (Fragoso Jr 2009), a temperatura superficial da água foi tão bem estimada pelo modelo *Air2Water* quanto no Lago Superior, de dinâmica térmica distinta e onde processos de estratificação podem ser observados.

Quanto ao desempenho e à eficiência da PSO em função do número de partículas utilizadas no ajuste do modelo *Air2Water* à Lagoa Mangueira, são apresentados na Tabela 1 os resultados obtidos em termos de função-objetivo e de tempo médio de processamento consumido computacionalmente. É possível identificar a manutenção dos valores médios de NSE e RMSE, indicando que a redução da quantidade de partículas da PSO de 1000 para 100 não comprometeu o desempenho do processo de ajuste do modelo *Air2Water*. Além disso, a redução da quantidade de partículas da PSO representou um tempo de execução do processo de ajuste oito vezes menor. Este ganho computacional no processo de ajuste do modelo *Air2Water* sem comprometimento de desempenho já havia sido observado em aplicação junto ao Lago Superior, com redução da quantidade *default* de 2000 partículas na PSO (Saldanha-Ferrari et al. 2023).

Função objetivo	Quantidade de partículas (PSO)	Período		Tempo médio de processamento (min)
		Calibração	Verificação	
NSE	1000	0,96	0,95	14,69
	100	0,96	0,95	1,72
RMSE (°C)	1000	0,85	0,95	14,97
	100	0,85	0,96	1,77

Tabela 1 – Desempenho e eficiência do ajuste do modelo *Air2Water* frente ao número de partículas na PSO.



CONCLUSÃO

Neste trabalho, o modelo de estimativa da temperatura da água *Air2Water* foi ajustado à Lagoa Mangueira a partir de séries temporais diárias de temperatura do ar medidas *in situ* e de temperatura superficial da água obtida via sensoriamento remoto. Os valores de função-objetivo obtidos indicaram um ajuste do modelo *Air2Water* bastante satisfatório, com NSE = 0,96 (0,95) e RMSE = 0,85°C (0,95°C) para o período de calibração (verificação). Tal desempenho supera o do estudo que avaliou tendências de temperatura do ar e da água junto à Lagoa Mangueira aplicando o modelo *Air2Water*, o que aponta para a possibilidade de melhor representação da temperatura superficial da água quando os dados obtidos a partir de sensores termais passam por uma correção do efeito de pele fria.

Ademais, foi verificado que o número de partículas da PSO, método de otimização acoplado ao modelo *Air2Water*, pode ser reduzido sem comprometimento do seu processo de ajuste. Similar à outra aplicação do modelo *Air2Water* junto ao Lago Superior, os resultados aqui obtidos para a Lagoa Mangueira indicaram manutenção de desempenho do modelo *Air2Water* em estimar a temperatura da água de lagos de morfometria diferente, ainda que com menos partículas na PSO. Para além da redução do valor *default* de 2000 partículas do modelo *Air2Water*, reduzir o número de partículas de 1000 para 100 na PSO possibilitou um tempo médio de execução do processo de ajuste à Lagoa Mangueira oito vezes menor. Tal ganho computacional reforça a aplicabilidade do modelo *Air2Water* em estudos na área de limnologia e modelagem da qualidade da água.

REFERÊNCIAS

- BARBOSA, C., NOVO, E., & MARTINS, V. (2019). *Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: princípios e aplicações*. Instituto Nacional de Pesquisas Espaciais, Volume 1.
- CAVALCANTI, J., MOTTA-MARQUES, D., & FRAGOSO JR, C. (2016). Process-based modeling of shallow lake metabolism: Spatio-temporal variability and relative importance of individual processes. *Ecological Modelling*, 323, pp. 28 - 40. doi:<http://dx.doi.org/10.1016/j.ecolmodel.2015.11.010>
- COLLISCHONN, W., & DORNELLES, F. (2015). *Hidrologia para Ciências Ambientais*. Porto Alegre: Associação Brasileira de Recursos Hídricos (ABRH).
- FRAGOSO JR., C. (2009). Teste submetida ao Programa de Pós Graduação em Recursos Hídricos e Saneamento Ambiental (Instituto de Pesquisas Hidráulicas/Universidade Federal do Rio Grande do Sul). *Modelagem tridimensional da estrutura trófica em ecossistemas aquáticos rasos*. Porto Alegre.
- GUO, L., ZENG, H., WU, Y., FAN, L., WEN, M., LI, J., . . . ZHANG, B. (2022). An integrated dataset of daily lake surface water temperature over the Tibetan Plateau. *Earth System Science Data*, pp. 3411–3422.
- HANDCOCK, R., TORGERSEN, C., CHERKAUER, K., GILLESPIE, A., TOCKNER, K., FAUX, R., & TAN, J. (2012). Thermal Infrared Remote Sensing of Water Temperature in Riverine Landscapes. *Fluvial Remote Sensing for Science and Management*.
- KENNEDY, J., & EBERHART, R. (1995). Particle Swarm Optimization. *IV*, 1942-1948. Perth, WA, Australia: Institute of Electrical and Electronics Engineers (IEEE).
- LEWIS JR, W. (1983). A revised classification of lakes based on mixing. *Canadian Journal of Fisheries and Aquatic Sciences*, 40 (10), pp. 1779 - 1787. doi:<https://doi.org/10.1139/f83-207>
- LIVINGSTONE, D., & PADISÁK, J. (2007). Large-scale coherence in the response of lake surface-water temperatures to synoptic-scale climate forcing during summer. *Limnology and Oceanography*(52 (2)), pp. 896–902.
- MOTOVILOV, Y., GOTTSCHALK, L., ENGELAND, K., & RODHE, A. (1999). Validation of a distributed hydrological model against spatial observations. *Agricultural and forest meteorology*, 98-99, pp. 257 - 277.



- PICCOLROAZ, S. (2016). Prediction of lake surface temperature using the Air2water model: guidelines, challenges, and future perspectives. *Advances in Oceanography and Limnology*, 7(1), pp. 36-50. doi:10.4081/aio1.2016.5791
- PICCOLROAZ, S., TOFFOLON, M., & MAJONE, B. (2013). A simple lumped model to convert air temperature into surface water temperature in lakes. *Hydrology and Earth System Sciences*.
- SALDANHA-FERRARI, C., BRAVO, J., MARQUES, D., & RODRIGUES, L. (2023). XXV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. *Desempenho da PSO no ajuste de modelo de estimativa de temperatura da água de lagos*. Aracaju.
- STUMM, W. (2004). Chemical processes regulating the composition of lake waters. Em P. O'SULLIVAN, & C. REYNOLDS, *The Lakes Handbook: Limnology and Limnetic Ecology*. Oxford: Blackwell Science .
- TAVARES, M. (2023). Análise do impacto de mudanças ambientais na variação espaço-temporal da qualidade da água de lagos rasos costeiros brasileiros por sensoriamento remoto. *Ph.D. Thesis, Federal University of Rio Grande do Sul, 197, Postgraduate Program in Water Resources and Environmental Sanitation*.
- TAVARES, M., FARIAS, A., MARQUES, D., & RUHOFF, A. (2019a). Dissertação apresentada ao Programa de Pós Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul. *Estimativa da temperatura superficial da água por sensores remotos: acurácia e aplicabilidade com modelos de temperatura, 11*. Porto Alegre.
- TAVARES, M., MARQUES, D., & FRAGOSO JR., C. (2019b). Combinando modelo de temperatura da água e sensoriamento remoto para estimar o efeito da mudança climática sobre a temperatura da Lagoa Mangueira-RS. *XXIII Simpósio Brasileiro de Recursos Hídricos*.
- TOFFOLON, M., PICCOLROAZ, S., MAJONE, B., SOJA, A.-M., PEETERS, F., SCHMID, M., & WÜEST, A. (2014). Prediction of surface temperature in lakes with different morphology using air temperature. *Limnology Oceanography*, 59(6).
- WAN, Z. (2013). Users' Guide: MODIS Land Surface Temperature Products (Collection 6). ERI, University of California, Santa Barbara.
- WAN, Z., HOOK, S., & HULLEY, G. (2021). *MODIS/Terra Land Surface Temperature/Emissivity Daily L3 Global 1km SIN Grid V061*. (USGS NASA) Acesso em 15 de 05 de 2022, disponível em LP DAAC MOD11A1.
- WANG, W., SHI, K., WANG, X., ZHANG, Y., QIN, B., ZHANG, Y., & WOOLWAY, R. (2024). The impact of extreme heat on lake warming in China. *Nature Communications*. doi:https://doi.org/10.1038/s41467-023-44404-7
- WIELICZKO, A., CROSSETTI, L., CAVALCANTI, J., HESSEL, M., MARQUES, D., & RODRIGUES, L. (2021). Meteorological drivers and ENSO influence on phytoplankton biomass dynamics in a shallow subtropical lake. *Springer Nature - Environmental Monitoring and Assessment*.