



## PREVENDO O NÍVEL D'ÁGUA EM AQUÍFEROS: O QUE TEMOS FEITO E COMO O APRENDIZADO DE MÁQUINAS PODE AJUDAR

Gabriel Pelizari <sup>1,2</sup>, Ana Elisa Silva de Abreu <sup>1</sup>.

<sup>1</sup> Universidade Estadual de Campinas. Rua Carlos Gomes, 250. Campinas (SP).

<sup>2</sup> Water Services and Technologies (WST). Florianópolis (SC).

[pelizari.gabriel00@gmail.com](mailto:pelizari.gabriel00@gmail.com); [aeabreu@unicamp.br](mailto:aeabreu@unicamp.br).

**Palavras-Chave:** Nível d'água subterrânea; Predição; Machine Learning.

### INTRODUÇÃO

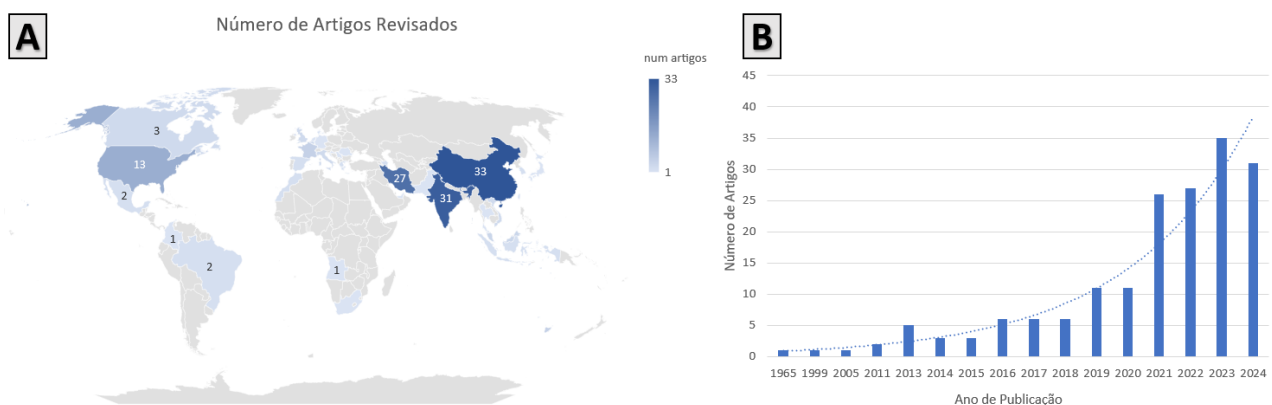
Diversas regiões do planeta têm observado um rápido rebaixamento do nível da água (NA) subterrânea em décadas recentes, sofrendo cada vez mais com a escassez. Prever com acurácia o NA é, então, crucial para a gestão e criação de políticas públicas que busquem segurança hídrica (Wee Boo et al., 2024). Visando a esse tipo de predição, abordagens estocásticas (baseadas em modelos físico-conceituais) apresentam-se mais consolidadas, enquanto o uso de *Machine Learning* (ML) vem crescendo. Este estudo buscou revisar a aplicação, características, diferenças e limitações das abordagens empregadas na previsão do nível d'água em aquíferos e comparar o uso de diferentes abordagens na predição do NA, buscando caracterizá-las e diferenciá-las em suas limitações e potencialidades.

### MÉTODO

Foram pesquisadas as bases de dados científicas Science Direct e Web of Science. Foram empregadas duas *strings* de busca: (1) (“Ground Water Level” OR “Ground Water Table” OR “GWL”) AND (“Prediction” OR “Forecast”) AND “Machine Learning” e (2) (“Ground Water Level” OR “Ground Water Table” OR “GWL”) AND (“Prediction” OR “Forecast”) NOT “Machine Learning”. A busca foi pensada de forma a separar trabalhos de previsão do NA baseados em ML de trabalhos sem o uso de ML. Não foi estabelecido um limite temporal. Os artigos foram lidos visando excluir os não pertinentes ao tema e extrair informações como ano de publicação, país onde se localiza a área de estudo e técnicas de predição utilizadas.

### RESULTADOS E DISCUSSÃO

Ao todo 175 artigos foram revisados. China, Índia e Irã mostraram-se grandes expoentes no tema pesquisado. Por sua vez, países da América do Sul, América Central e África apresentaram juntos menos de 4% dos artigos revisados. O Brasil não apresentou nenhum artigo envolvendo a aplicação de ML na predição de NA, evidenciando a defasagem brasileira no tema (**Figura 1**). Foi observado um crescimento exponencial do número de artigos publicados por ano. Estas observações estão em acordo com Wee Boo *et al.* (2024).



**Figura 1.** A) Distribuição geográfica dos 175 artigos revisados B) Número de artigos por ano de publicação.



Da bibliografia analisada, 29 artigos não utilizaram *Machine Learning*, lançando mão de métodos como softwares de modelagem (por exemplo Feflow, Modflow, 16 artigos), *AutoRegressive Integrated Moving Average* (ARIMA) ou *AutoRegressive Moving Average* (ARMA) (5 artigos), *Funções de Resposta a Impulso* (FRI) (4 artigos) e outros (4 artigos). Os demais 146 artigos, com a aplicação de *Machine Learning*, utilizaram principalmente os algoritmos de *Artificial Neural Networks* (ANN) (78 artigos), *Support Vector Machines* (SVM) (34 artigos), *Long Short-Term Memory* (LSTM) (26 artigos) e *Random Forest* (RF) (25 artigos). Estes quatro tipos de modelo correspondem a 4/5 dos modelos utilizados nos artigos revisados. Os demais 45 artigos utilizaram *Linear Regression*, *Gradient Boosting*, *Xtreme Gradient Boosting*, *Convolutional Neural Networks*, *Decision Trees*, *ANFIS* ou outros.

A abordagem estocástica, buscando representar fenômenos físicos através de modelos conceituais matemáticos, é compreendida como a abordagem clássica na modelagem hidrogeológica. Seu sucesso se deve por apresentar procedimentos matemáticos bem definidos, proporcionando bom entendimento das dinâmicas por trás das observações ao passo que ainda é capaz de produzir previsões moderadamente satisfatórias (Chakraborty *et al.*, 2020). Na prática, porém, esta abordagem requer a inferência e calibração de diversos parâmetros, sendo computacionalmente custoso, tendo parâmetros assumidos a partir da literatura e sendo limitada pela natureza não-linear das flutuações do NA em um aquífero (Rezaie-Balf *et al.*, 2017). Isto gera uma lacuna preenchida por algoritmos de ML capazes de capturar adequadamente a natureza não-linear de fenômenos hidrogeológicos. É possível então aproveitar séries históricas já disponíveis para modelar processos hidrogeológicos complexos sem a necessidade de uma calibração computacionalmente custosa, sem adoção de parâmetros a partir da literatura e capazes de realizar previsões com maior acurácia que modelagens tradicionais (Almuhaylan *et al.*, 2020). Entretanto, é necessário ter em mente que a adoção de algoritmos conhecidos como 'black-box' torna complexa a compreensão de uma previsão e, portanto, pode não ser ideal para explorar os mecanismos de controle por trás de um fenômeno (Wee Boo *et al.*, 2024).

De modo geral, o uso de *Machine Learning* não exclui o uso de modelos físicos-conceituais e *vice-versa*. A adoção de um ou outro dependerá então do propósito de cada estudo, seja ele compreender os mecanismos de controle de um fenômeno ou realizar uma predição com boa acurácia, assim como dos dados e recursos disponíveis. A adoção conjunta destes métodos através de uma modelagem híbrida pode ainda constituir uma ótima confluência das forças de cada abordagem e proporcionar estudos hidrogeológicos cada vez mais completos.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Wee Boo K.B., El-Shafie, A., Othman F., Khan Md.M.H., Birima A.H., Ahmed A.N. 2024. Groundwater level forecasting with machine learning models: A review. *Water Research*. Volume 252. (121249). ISSN 0043-1354. 10.1016/j.watres.2024.121249.
- Chakraborty, P.K. Maity, S. Das. Investigation, simulation, identification, and prediction of groundwater levels in coastal areas of Purba Midnapur, India, using MODFLOW. 2020. *Environ. Dev. Sustain.*, 22, pp. 3805-3837, 10.1007/s10668-019-00344-1
- Rezaie-Balf M., Naganna S.R., Ghaemi, P.C.A. DekaWavelet coupled MARS and M5 Model Tree approaches for groundwater level forecasting. 2017. *J. Hydrol.*, 553, pp. 356-373, 10.1016/j.jhydrol.2017.08.006
- Almuhaylan M.R., Ghumman A.R., Al-Salamah I.S., Ahmad A., Ghazaw Y.M., Haider H., Shafiquzzaman M. 2020. Evaluating the impacts of pumping on aquifer depletion in arid regions using MODFLOW ANFIS *Ann. Water*, 12, 10.3390/w12082297