

CALIBRAÇÃO DE VALORES DE RUGOSIDADE DE SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA UTILIZANDO PINNS E GCN

Jordana Alaggio¹; Pedro Diaz²; Gustavo Meirelles³ & Bruno Brentan⁴

Palavras-Chave – Rede de distribuição de água, Inteligência Artificial, Metamodelagem fisicamente informada, Calibração de rugosidade.

INTRODUÇÃO

Redes de distribuição de água (RDAs) são sistemas complexos cuja gestão eficiente é desafiada por fatores como crescimento urbano, variabilidade da demanda e envelhecimento da infraestrutura. Modelos hidráulicos tradicionais, embora amplamente utilizados, exigem alta capacidade computacional e calibração de parâmetros incertos, como rugosidade e demanda (SCHNEIDER et al., 2022). Como alternativa, metamodelos baseados em dados têm ganhado destaque, apesar das limitações em interpretabilidade e da forte dependência da qualidade dos dados (LORENZ; PELZ, 2020).

Este trabalho propõe um metamodelo híbrido que combina redes neurais fisicamente informadas (PINNs) e redes neurais baseadas em grafos (GNNs), integrando dados de sensores, leis físicas e a topologia da rede. A abordagem busca reduzir a necessidade de dados extensos, aumentar a generalização e viabilizar aplicações quase em tempo real, contribuindo para a construção de Gêmeos Digitais em RDAs. No contexto da utilização complementar do metamodelo baseado em dados com modelos hidráulicos tradicionais, o metamodelo foi utilizado para estimar a rugosidade a partir de dados de pressão e vazão estimados. A partir disso, construiu-se uma terceira camada de dados, correspondente à rugosidade, que é inserida no modelo físico com o intuito de aproximar a estimativa do estado hidráulico da rede feito pelo modelo de base física à sua condição real.

METODOLOGIA

A construção do metamodelo orientado por dados foi implementada em Python, utilizando as bibliotecas PyTorch Geometric (ROZEMBERCZKI et al., 2021), para o processamento de redes neurais, e WNTR (KLISE et al., 2017), para integração com o EPANET na realização das simulações hidráulicas de comparação. Como estudo de caso, adotou-se a rede Modena (BRAGALLI et al., 2008), composta por 268 nós, 317 tubulações e 4 reservatórios. Sensores de vazão foram alocados nas saídas dos reservatórios, totalizando quatro unidades, localizadas nos tubos 336, 335, 331 e 330. Os sensores de pressão, por sua vez, foram instalados nos nós 248, 246, 101, 263 e 264.

Inicialmente, o modelo foi treinado com dados horários dos sensores gerados por simulações hidráulicas ao longo de um ano simulado e produziu como saída estimativas de vazão e pressão para os elementos da rede não monitorados. Após o treinamento, o metamodelo foi capaz de estimar as vazões e pressões nos tubos e nós não monitorados. Com base nessas estimativas, procedeu-se à estimação retroativa (*hindcast*) dos valores de rugosidade das tubulações.

O cálculo da rugosidade foi realizado por meio da equação de Hazen-Williams. A partir das pressões estimadas, obteve-se a perda de carga ao longo dos tubos, e, juntamente com os valores de

1) Departamento de Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais: Av. Pres. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, (31) 3409-1870, jordanaalaggio@gmail.com

2) Universidade Federal de Minas Gerais: Av. Pres. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, (31) 3409-1870, pedrovrdiaz03@gmail.com

3) Departamento de Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais: Av. Pres. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, (31) 3409-1870, gustavo.meirelles@ehr.ufmg.br

4) Departamento de Hidráulica e Recursos Hídricos, Universidade Federal de Minas Gerais: Av. Pres. Antônio Carlos, 6627 - Pampulha, Belo Horizonte - MG, 31270-901, (31) 3409-1870, brentan@ehr.ufmg.br

vazão, foi possível calcular o coeficiente de rugosidade (C). Ressalta-se que essa equação é aplicável apenas a escoamentos turbulentos. Em trechos onde a vazão, em determinados instantes, era suficientemente baixa para descharacterizar o regime turbulento, a equação apresentou falhas de convergência. Nesses casos, os valores incompatíveis foram identificados e substituídos pela média dos coeficientes válidos, assegurando a continuidade e estabilidade do processo de estimativa.

RESULTADOS

Utilizou-se o coeficiente de determinação (R^2) e o erro médio absoluto (MAE) para avaliar o desempenho do metamodelo na predição de vazão e pressão da rede, em relação aos valores originais. Os dados de vazão e pressão estimados pelo metamodelo, que serviram de base para o cálculo da rugosidade, apresentaram valores de R^2 de 0,999 e 0,976, respectivamente, quando comparados aos dados originais. Os valores de MAE obtidos foram de 0,143 L/s para vazão e 0,488 m para pressão. Apesar do elevado coeficiente de determinação relacionado às previsões de vazão e pressão fornecidas pelo metamodelo para os nós e tubos não monitorados da rede, observou-se que a estimativa do coeficiente de rugosidade C, obtida por meio da aplicação inversa da equação de Hazen-Williams, apresenta imprecisões relevantes, especialmente em condições hidráulicas específicas.

A estimativa da rugosidade mostrou-se sensível à qualidade das pressões previstas, resultando em erros significativos nos coeficientes de rugosidade, especialmente em condições hidráulicas não compatíveis com o regime turbulento. O teste alternando entre os valores reais e estimados de vazão e pressão como entradas no cálculo da rugosidade, indicou que imprecisões na pressão têm impacto mais expressivo do que na vazão para o cálculo de rugosidade. Apesar dessas limitações, a abordagem híbrida demonstrou potencial para aprimorar a calibração de modelos hidráulicos, sugerindo que a combinação de camadas observacionais, físicas e baseadas em dados pode contribuir para a construção de gêmeos digitais mais robustos. Como avanço futuro, recomenda-se explorar a equação de perda de carga universal e o uso direto de redes neurais para estimativa da rugosidade, ampliando a aplicabilidade da metodologia em diferentes cenários operacionais.

REFERÊNCIAS

- BRAGALLI, C.; D'AMBROSIO, C.; LEE, J.; LODI, A.; TOTH, P. (2008). "Water Network Design by MINLP".
- KLISE, K. A.; HART, D. B.; MORIARTY, D.; BYNUM, M. L.; MURRAY, R.; BURKHARDT, J.; HAXTON, T. (2017). "Water Network Tool for Resilience (WNTR) User Manual". Washington, D.C.: U.S. Environmental Protection Agency.
- LORENZ, I.-S.; PELZ, P. (2020). "Optimal Resilience Enhancement of Water Distribution Systems". Water, v. 12, n. 9, p. 2602.
- ROZEMBERCZKI, B.; SCHERER, P.; HE, Y.; PANAGOPOULOS, G.; RIEDEL, A.; ASTEFANOAEI, M.; KISS, O.; BERES, F.; LÓPEZ, G.; COLLIGNON, N.; SARKAR, R. (2021). "PyTorch Geometric Temporal: Spatiotemporal Signal Processing with Neural Machine Learning Models".
- SCHNEIDER, M. Y.; QUAGHEBEUR, W.; BORZOOEI, S.; FROEMELT, A.; LI, F.; SAAGI, R.; WADE, M. J.; ZHU, J.-J.; TORFS, E. (2022). "Hybrid Modelling of Water Resource Recovery Facilities: Status and Opportunities". Water Science & Technology, v. 85, n. 9.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) pelo financiamento à participação no congresso sob processo número PCE-00429-25 e à Coordenação de Aperfeiçoamento de Nível Superior (CAPES) pelo apoio financeiro.