



# DETECÇÃO E REGIONALIZAÇÃO DE VAZAMENTOS EM SISTEMAS DE ABASTECIMENTO DE ÁGUA USANDO REDES NEURAIS DE BASE FÍSICA

**Palavras-Chave:** redes neurais de base física, detecção de vazamentos, sistemas de abastecimento de água

**Autores(as):**

**Henrique Di Bernardo Dantas, FECFAU – Unicamp**

**Daniel Barros, FECFAU – Unicamp**

**Prof. Dr. José Gilberto Dalfré Filho (orientador), FECFAU – Unicamp**

**Prof. Dr. Brunto Brentan (co-orientador), EHR – UFMG**

---

## INTRODUÇÃO:

A identificação e a localização de vazamentos em sistemas de abastecimento de água são desafios cruciais para garantir a eficiência operacional, reduzir perdas e evitar danos estruturais. Estratégias tradicionais de detecção muitas vezes demandam investimentos significativos em sensores e inspeções de campo. Nesse contexto, redes neurais de base física (Physics-Informed Neural Networks – PINNs) surgem como uma alternativa promissora, pois combinam conhecimentos de modelagem hidráulica com aprendizado de máquina, contribuindo para diminuir erros de estimativa e fornecer resultados mais robustos (MENAPACE *et al.*, 2024).

A utilização de metamodelos (também chamados surrogate models) em sistemas de abastecimento de água tem se intensificado nas últimas décadas como forma de reduzir a dependência de modelos hidráulicos tradicionais, que são mais caros em termos computacionais e complexos em termos de calibração. O princípio desses metamodelos é representar o comportamento hidráulico (por exemplo, pressões e vazões) a partir de dados gerados ou observados, sem necessariamente resolver todas as equações de um modelo físico completo. Dessa forma, obtêm-se estimativas mais rápidas, úteis em aplicações de operação em tempo quase real, otimização e identificação de anomalias.

Em relação à detecção e regionalização de vazamentos, há um interesse crescente em integrar técnicas de aprendizado de máquina com conhecimentos de hidráulica para reduzir perdas de água e gastos operacionais. De abordagens totalmente data-driven, baseadas apenas em medições históricas, caminha-se para métodos híbridos que adicionam restrições físicas ao processo de aprendizado (Physics-Informed Neural Networks – PINNs). Esses métodos permitem maior robustez do modelo, pois, além de aprender padrões nos dados, o algoritmo respeita princípios fundamentais, como a conservação de massa e de energia ao longo da rede (MENAPACE *et al.*, 2024). Nesse sentido, a adoção de metamodelos baseados em redes neurais de base física tem se mostrado promissora para detectar e localizar vazamentos com maior rapidez e confiabilidade.

Este trabalho apresenta os resultados de uma análise quantitativa da capacidade de um metamodelo baseado em redes neurais de base física (RNBF) de detectar vazamentos simulados na rede fictícia de Modena, a mesma utilizada por Menapace *et al.* (2024). A abordagem inclui o desenvolvimento de códigos em Python para

simulações hidráulicas de longo prazo, geração de dados anômalos (vazamentos) e treinamento de um metamodelo adaptado das propostas de Menapace *et al.* (2024).

## METODOLOGIA:

Nesta pesquisa, adaptamos o arcabouço apresentado em Menapace *et al.* (2024), que propõe um metamodelo híbrido que combina dados observados (pressão e vazão em pontos monitorados) com equações de balanço hidráulico (conservação de massa nos nós e energia nos trechos). Diferentemente de uma abordagem puramente data-driven, que pode resultar em previsões inconsistentes com a física do problema, o metamodelo de rede neural de base física (Physics-Informed Neural Network – PINN) “molda” a superfície de aprendizado de acordo com as equações hidráulicas fundamentais.

O modelo é estruturado em:

- **Entrada (inputs):** Leituras de pressão e vazão em nós ou trechos monitorados ao longo do tempo.
- **Rede Neural:** Neste trabalho, foi utilizado a arquitetura FCN (Fully Connected Network) de aprendizado de máquina para o desenvolvimento da RNBF, na qual a perda global é definida como combinação das perdas do modelo computacional e dos resíduos das equações de conservação de massa e energia, que caracterizam a parte física do modelo. O algoritmo FCN é equivalente ao Multi-layer Perceptron (MLP).
- **Restrições físicas:** Um termo adicional na função de custo da rede neural impõe a minimização de resíduos nas equações de conservação de massa e energia (por exemplo, Hazen-Williams ou Darcy-Weisbach). Assim, mesmo em regiões pouco monitoradas, o modelo tende a fornecer valores coerentes com a hidráulica.

Além disso, o modelo possui uma Função Perda (Loss Function), que combina:

- **Termo de ajuste aos dados (data-driven)**, que minimiza o erro entre as saídas da rede e os valores efetivamente observados ou gerados por simulações;
- **Termo físico (physics-informed)**, que avalia o quão bem as previsões de pressão e vazão satisfazem as equações de balanço (resíduos de massa e energia). Este termo atua como “segunda distorção” no processo de aprendizado, garantindo maior coerência hidráulica.

Dessa forma, a rede neural é treinada tanto para reproduzir observações quanto para permanecer fiel às equações básicas do escoamento em regime permanente, reduzindo erros grosseiros, especialmente fora das regiões monitoradas.

Para a detecção de vazamentos, será utilizada a metodologia proposta por Barros *et al.* (2025). Em linhas gerais:

- **Geração de dados e simulações iniciais:** Executa-se um grande número de simulações (por exemplo, 10 anos) com cenários variados de demanda e vazamentos artificiais (10 L/s), distribuídos aleatoriamente em diferentes pontos. Além disso, mantém-se uma simulação de referência (sem vazamentos) para comparação.
- **Treinamento do PINN:** A rede neural de base física recebe séries de pressão e vazão (medidas e simuladas), juntamente com as equações de conservação de massa e energia. Ajusta-se a quantidade de camadas, neurônios, visando minimizar o termo combinado (erro de dados + erro físico). Assim que treinado, o modelo passa a fornecer previsões de pressão e vazão em todos os nós/trechos, mesmo fora dos pontos monitorados, preservando coerência hidráulica.
- **Processamento dos resíduos:** Uma vez operacional, o metamodelo gera previsões de pressão/vazão e as compara com os valores reais observados (ou esperados). A diferença (resíduo) tende a aumentar em nós/trechos afetados por vazamentos, pois há desacordo entre o estado previsto (sem vazamento significativo) e o estado real. Se o resíduo ultrapassa um certo limiar estatístico, dispara-se um alerta de possível vazamento.

- **Construção de um limiar:** é feita uma separação do banco de dados para treinamento, validação e, em seguida, inclusão dos vazamentos na simulação. A partir dos dados sem vazamentos, é possível construir um limiar baseado nos valores das médias e desvios-padrão dos parâmetros analisados, que servirão como uma *flag leak*, indicando ocorrência do vazamento.

Para a criação de um banco de dados, são realizadas simulações hidráulicas em linguagem Python (utilizando a biblioteca WNTR), capaz de abarcar cenários de demanda ou vazamento aleatórios. A cada iteração de treinamento, são calculadas as perdas (data-driven e physics-informed) e realizadas atualizações dos pesos da rede para reduzir esses erros. Após calibrado, o metamodelo processa leituras on-line de sensores e fornece previsões de pressão e vazão para nós não monitorados. Identificando desvios, aponta trechos/regiões mais prováveis de conter vazamentos.

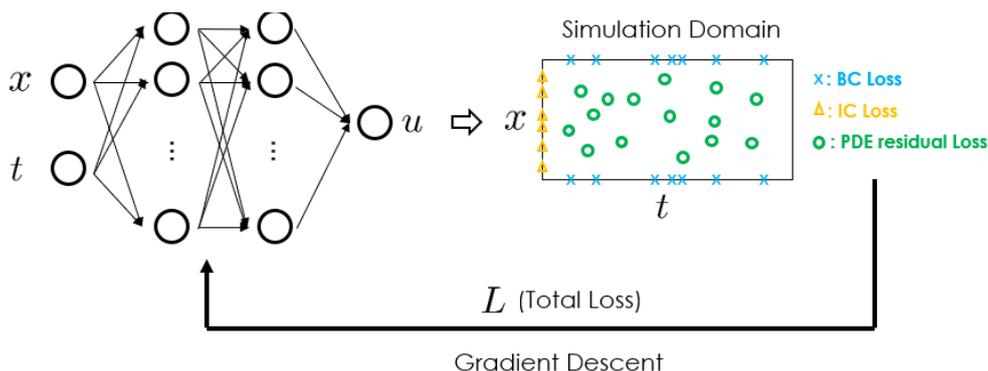


Figura 1: Desenho esquemático do funcionamento de uma rede neural.

## RESULTADOS E DISCUSSÃO:

Para avaliar os resultados, foi feita uma análise quantitativa de modo a verificar a qualidade do modelo na detecção dos vazamentos. Em um primeiro momento, a quantificação foi feita desconsiderando efeitos das equações de energia (4) e, em seguida, aplicando-as ao modelo, de modo que fosse possível entender o efeito da energia na sua capacidade de detecção dos vazamentos. As Figuras 2 a 5 mostram o comportamento das métricas utilizadas na análise ( $MAE$  e  $R^2$ ) de pressão, vazão, resíduo de massa e energia, respectivamente, ao longo de 10 anos de simulação. Nos primeiros 8 anos, a simulação é feita sem vazamentos e, nos últimos 2 anos, são inseridos 15 vazamentos aleatórios de  $10 \ell/s$ .

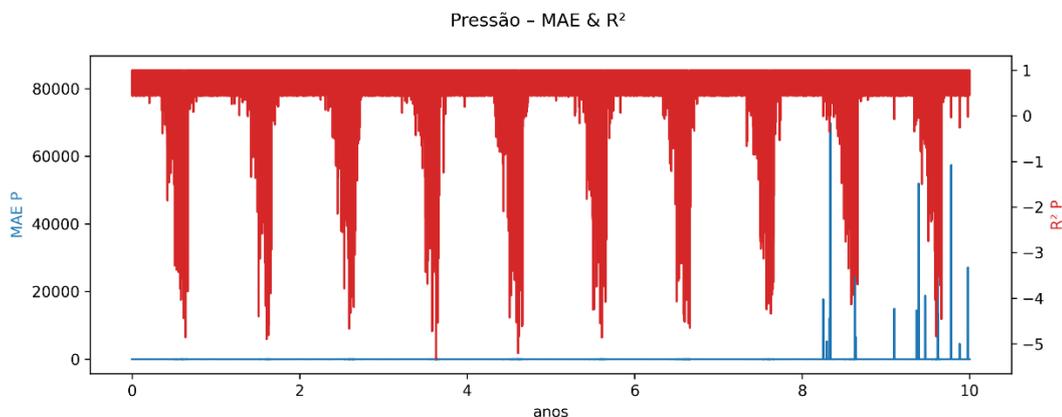


Figura 2 - Série histórica  $MAE(t)$  e  $R^2(t)$  de pressão ao longo dos 10 anos.

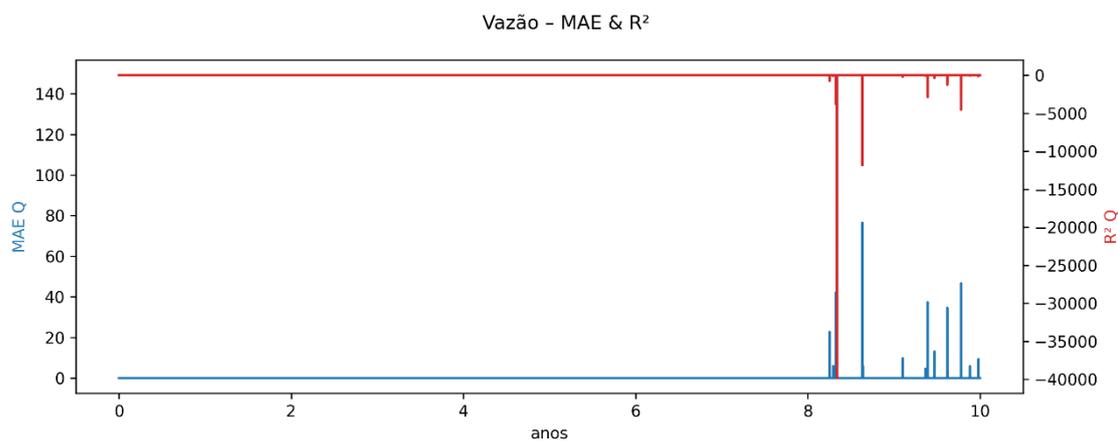


Figura 3 - Série histórica  $MAE(t)$  e  $R^2(t)$  de vazão ao longo dos 10 anos.

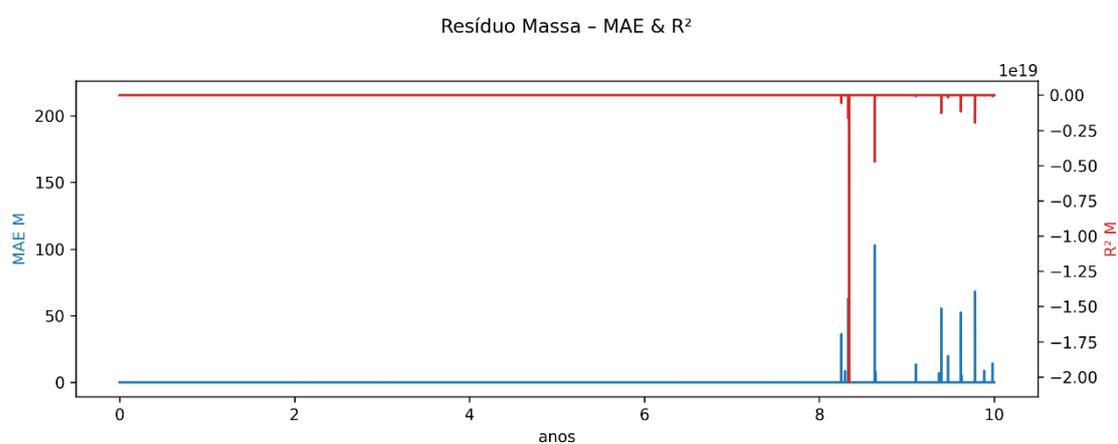


Figura 4 - Série histórica  $MAE(t)$  e  $R^2(t)$  do resíduo de massa ao longo dos 10 anos.

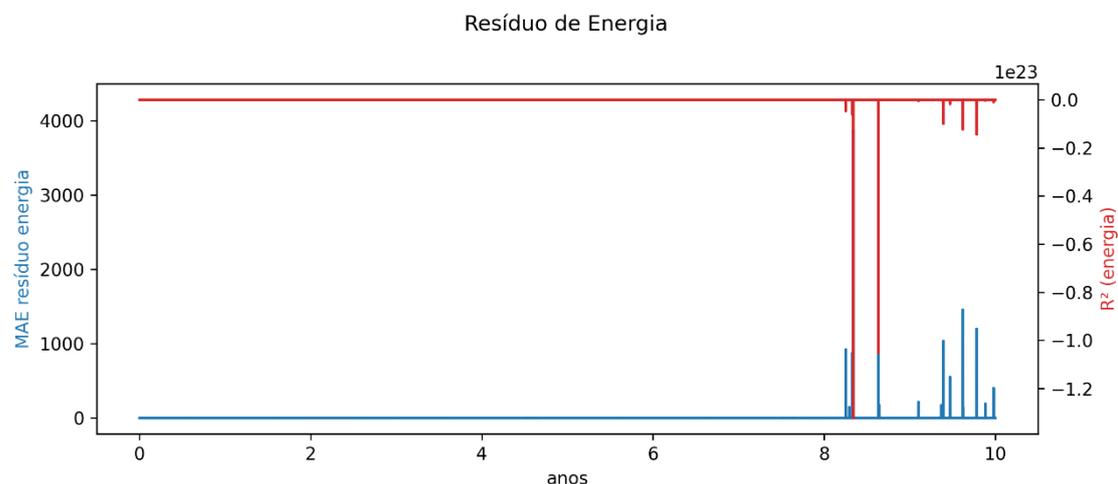


Figura 5 - Série histórica  $MAE(t)$  e  $R^2(t)$  de energia ao longo dos 10 anos.

Em conjunto com os gráficos nas Figuras 2 a 5, foram produzidos relatórios linha-a-linha e vazamento-a-vazamento que mostram: se o vazamento foi detectado (0 ou 1), o tempo de atraso (*delay*) e a fração de passos corretamente sinalizados; e um sumário de faixa que apresenta os vazamentos por faixa horária (madrugada, manhã, tarde, noite) e tipo de evento (instante  $\leq 2$  h, gradual  $> 2$  h), contabilizando: número total de vazamentos em cada período, quantidade detectada e o atraso médio.

Os resultados mostram que o metamodelo detecta todos os vazamentos com atraso “0”, graças ao monitoramento do desbalanceamento de massa e ao incremento abrupto das métricas  $MAE/R^2$ . É importante ressaltar que a detecção não é imediata, mas menor que o passo de tempo adotado nos cálculos ( $\Delta t = 1 h$ ), um resultado muito expressivo. A inclusão do termo de energia não influenciou nos resultados da primeira abordagem, com todos os vazamentos sendo igualmente detectados.

## CONCLUSÕES:

Partindo dos resultados mostrados, pode-se concluir a viabilidade de um metamodelo treinado via RNBF para detecção de vazamentos em redes de distribuição de água. Além da precisão dos resultados, a velocidade de detecção, em especial, mostra-se expressiva, uma vez que os métodos convencionais de busca manual de vazamentos levam tempo e podem não obter sucesso, ocasionando uma perda maior de recursos hídricos no processo.

## BIBLIOGRAFIA

BARROS, D.; ZANFEI, A.; MENAPACE, A.; MEIRELLES, G.; HERRERA, M.; BRENTAN, B. Leak detection and localization in water distribution systems via multilayer networks. Preprint, 2025.

MENAPACE, A.; ZANFEI, A.; CAETANO, J.; COVAS, D.; BRENTAN, B. Shall we always use hydraulic models? A novel water distribution system metamodel based on physics-informed neural networks. Water Research, Elsevier, 2024. Preprint.