FluHidros
I SIMPÓSIO NACIONAL DE MECÂNICA DOS FLUIDOS E HIDRÁULICA
Agosto/2022 – Ouro Preto/MG

ANÁLISE DE SENSIBILIDADE DO NÚMERO DE SENSORES NA CALIBRAÇÃO DE REDES DE DISTRIBUIÇÃO DE ÁGUA

Aloysio Portugal Maia Saliba [1]; Bruno Melo Brentan[2]; Gustavo Meirelles Lima [3]; Laura Sterle[4]
Harald Roclawski[5]; Thomas Krätzig[6]

RESUMO – a modelagem de redes de distribuição de água é um passo fundamental para que o planejamento e operação destes sistemas sejam feitos de forma eficiente. Entretanto, sua precisão está diretamente ligada à qualidade das informações disponíveis, susceptíveis a um alto grau de incerteza. Dentre os parâmetros com maior dificuldade de obtenção está a rugosidade das tubulações, uma vez que a deterioração de suas paredes durante sua vida útil depende de muitos fatores. Como não é viável técnica e economicamente realizar testes para sua determinação em todos os trechos, medições de pressão e vazão são feitas em pontos estratégicos para que seja feita a calibração de todo o modelo. Este procedimento pode resultar em valores fora da realidade, mas que matematicamente são capazes de reproduzir os resultados observados. Assim, neste trabalho será feita uma análise de sensibilidade da calibração da rede LENHS da UFMG. Esta rede possui nove anéis, com monitoramento de pressão em todos os seus 16 nós. Assim, a calibração do modelo será feita através de diferentes configurações de medição para observar as diferenças nos valores de rugosidade obtidos, com o objetivo de identificar um grau mínimo de monitoramento para que a calibração seja adequada.

Palavras-Chave – redes de distribuição de água, calibração, otimização

ABSTRACT– modelling water distribution networks is essential for an efficient planning and management. However, the accuracy of these models is directly connected to the quality of the available data, sensitive to a high degree of uncertainty. Among the most uncertain parameters is the pipe roughness, since its deterioration depends on many factors during its life cycle. It is not technical and economical feasible perform tests in every pipe of the network to determine its roughness. Thus, the pressure and flow measurements in strategic points are used to calibrate the model. This procedure often leads to nonsensical values of roughness, but capable to mathematically reproduce the observed results. In this paper, a sensitivity analysis is made in the calibration of the LENHS network of UFMG. This network has nine loops and all 16 nodes have a pressure sensor. Therefore, the calibration of the model is made for different monitoring configurations to observe the differences in the roughness determined, trying to identify a minimum degree of monitoring necessary for a plausible calibration.

Keywords – water distribution networks, calibration, optimization

INTRODUÇÃO

1) Universidade Federal de Minas Gerais – UFMG, Av. Antônio Carlos, 6627, Pampulha, Belo Horizonte – MG, aloysiosaliba@gmail.com
2) Universidade Federal de Minas Gerais – UFMG, Av. Antônio Carlos, 6627, Pampulha, Belo Horizonte – MG, brentan@ehr.ufmg.br
3) Universidade Federal de Minas Gerais – UFMG, Av. Antônio Carlos, 6627, Pampulha, Belo Horizonte – MG, gustavo.meirelles@ehr.ufmg.br
4) PhD Student, Institute for Fluid Mechanics and Turbomachinery, Technical University of Kaiserslautern, Germany, laura.sterle@mv.uni-kl.de
5) Senior Lecturer, Institute for Fluid Mechanics and Turbomachinery, Technical University of Kaiserslautern, Germany, roclawsk@mv.uni-kl.de
6) Managing Director, Dr. Krätzig Ingenieurgesellschaft mbH, Aachen, Germany, infoline@dr-kraetzig.com

O avanço tecnológico tem permitido que infraestruturas urbanas sejam monitoradas cada vez mais através da instalação de sistemas de baixo custo capazes de medir, armazenar e transmitir as informações com qualidade (Lambrou *et al.*, 2014). Técnicas de inteligência artificial como aprendizado de máquinas e algoritmos de otimização têm sido amplamente utilizadas para explorar as informações coletadas e aprimorar a gestão e operação destes sistemas (Mala-Jetmarova *et al*., 2017). Em redes de distribuição de água informações hidráulicas como pressão, vazão e níveis de reservatórios auxiliam a operação de estação elevatórias e a detecção de vazamentos (Brentan *et al.*, 2021; Manzi *et al.*, 2019).

Apesar dos bons resultados obtidos através da análise de dados, a incorporação de modelos hidráulicos se faz necessária quando situações não observadas devem ser avaliadas, como por exemplo o planejamento de expansão do sistema (Yazdani *et al.*, 2011). Para obtenção de uma boa resposta, as informações físicas, hidráulicas e topológicas do sistema devem ser definidas com a maior precisão possível. Ainda assim, o modelo possuirá uma incerteza, seja por falhas de medição, erros de leitura e a aleatoriedade da operação. Savic *et al.* (2009) definem calibração como a busca pela redução destas incertezas através de ajustes paramétricos do modelo, de forma que suas respostas se aproximem da realidade.

Em redes de distribuição de água a calibração é feita através de dois parâmetros principais: i) a rugosidade das tubulações, uma vez que a deterioração de suas paredes ao longo de sua vida útil depende de diversos fatores de difícil quantificação; e ii) a demanda nodal, uma vez que a variação do consumo de água é constante, afetando as medições observadas. Assim, estes parâmetros são ajustados no modelo de forma que condições hidráulicas conhecidas na realidade sejam reproduzidas. Entretanto, estas condições são conhecidas apenas em alguns pontos do sistema, uma vez que o monitoramento completo é inviável técnica e economicamente. Isto faz com que exista uma infinidade de soluções, pois o número de variáveis do problema é muito maior que o número de equações. Isto leva, em muitos casos, à valores de rugosidade e demanda matematicamente corretos mas fora da realidade. Diversos trabalhos buscam a melhoria do processo de calibração tentando estabelecer a melhor localização para a instalação dos sensores (Wéber e Hős, 2020) e também pela ampliação do banco de dados disponível através do uso de redes neurais (Meirelles *et al*., 2017).

Neste trabalho, é feita a calibração da rede do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) da Universidade Federal de Minas Gerais (UFMG). A rede é composta por nove anéis e possui sensores de pressão instalados em seus 16 nós, além de monitoramento de vazão na entrada do sistema. Desta forma, é possível avaliar a qualidade do processo de calibração de acordo com o nível de monitoramento do sistema. Devido à forma com que os sensores de pressão estão

instalados na rede, com diversos acessórios, optou-se pela calibração tanto da rugosidade das tubulações quanto do coeficiente de perda de carga localizada. O algoritmo *Particle Swarm Optimization* (PSO) foi utilizado para realizar a minimização do erro, definido como a diferença entre os valores simulados e observados, e assim, determinar os valores dos parâmetros de cada tubulação da rede.

METODOLOGIA

Coleta de Dados

O sistema de coleta de dados utilizado é baseado nos Sistemas de Supervisão e Aquisição de Dados (SCADA) tradicionais, com o objetivo de visualização e interpretação das informações, e atuação remota dos componentes, e também nos sistemas IoT (*Internet of Things*), que têm o objetivo de realizar a coleta de informações com baixo custo e de maneira descentralizada, de forma que um grande volume de informações possa ser adquirido, o que permite ações mais rápidas e eficientes (Vermesan *et al.*, 2013). A Figura 1 apresenta a arquitetura da plataforma IoT utilizada, composta por quatro placas ESP32 que recebem o sinal de corrente dos sensores (4 a 20 mA) instalados na rede, e estão conectadas a uma unidade Raspberry Pi que possui o *software* Thingsboard, que permite a visualização dos dados coletados. O protocolo de comunicação MQTT (*Message Queuing Telemetry Transport*) é utilizado para acelerar e reduzir o tamanho dos dados coletados.

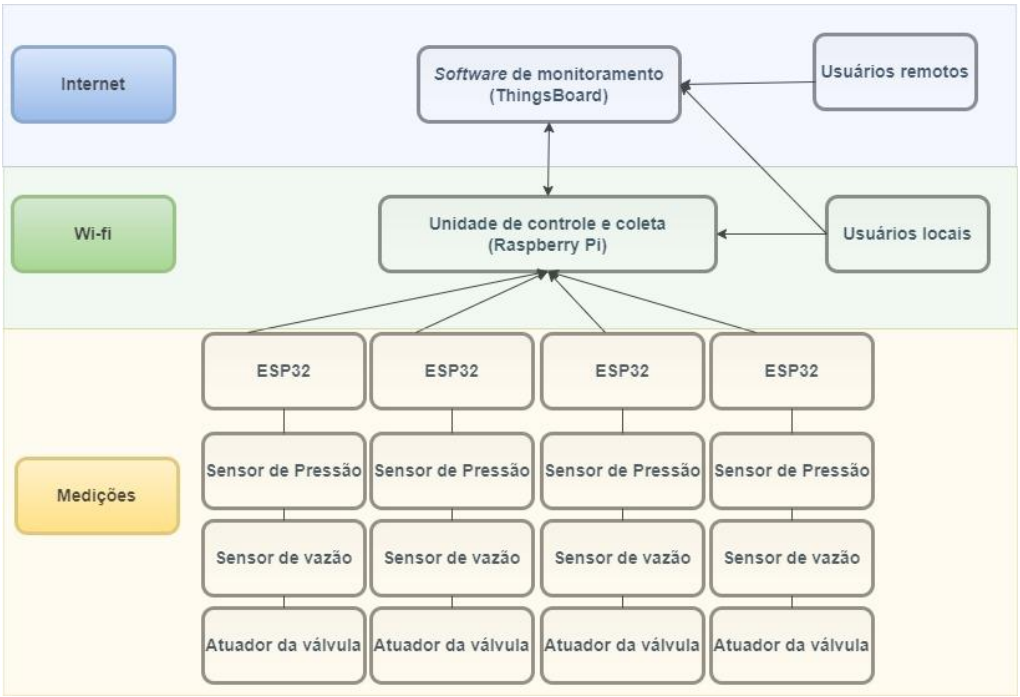

Figura 1 – Arquitetura do sistema de coleta de dados utilizado (Fonte: Moraes *et al.*, 2021)

Os sensores de pressão possuem faixa de medição de 0 a 10 m, e estão localizados em todos os nós da rede, conforme ilustra a Figura 2. Como procedimento de ensaio, duas condições de vazão foram avaliadas: 3,2 e 3,9 L/s. Não há nenhum ponto de consumo na rede, ou seja, a vazão de entrada do sistema é igual a de saída. Para cada uma destas condições os valores de pressão foram coletados durante um minuto, sendo utilizado o valor médio encontrado no procedimento de calibração.

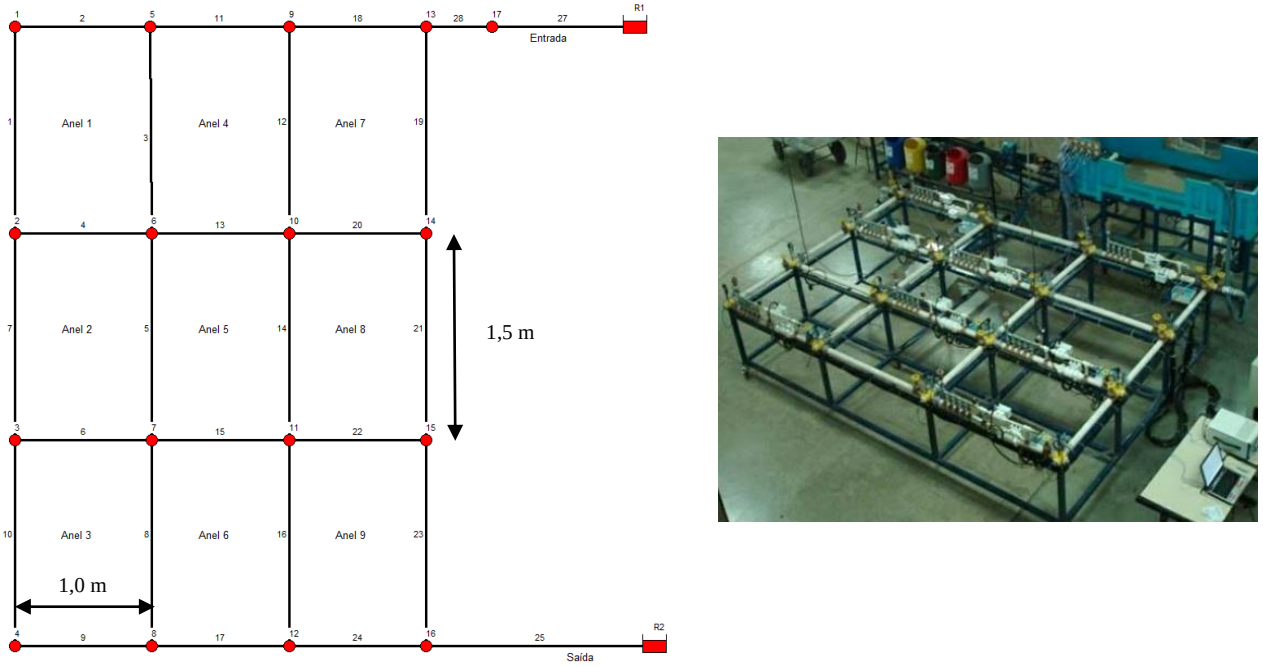

(a) **(b)**

Figura 2 – Rede LENHS: a) Modelo do EPANET; b) Vista aérea do laboratório.

Calibração

A calibração visa o ajuste de parâmetros do modelo para que este seja capaz de reproduzir os dados coletados em campo, ou seja, para que o modelo seja capaz de retratar a realidade, e assim, simular diferentes condições que não seriam possíveis de testar em campo (Savic *et al.*, 2009). Em redes de distribuição de água, a rugosidade das tubulações e a demanda nodal são os dois parâmetros comumente calibrados devido à sua grande incerteza: as tubulações devido ao nível de deterioração, e a demanda devido à variabilidade do consumo durante o período de medição. Os ensaios realizados na rede LENHS visam a calibração apenas da rugosidade das tubulações, uma vez que, por ser uma rede piloto, os pontos de consumo são conhecidos e monitorados. Assim, durante os ensaios realizados não houve nenhum consumo, ou seja, a vazão de entrada da rede é a mesma de saída.

Devido à configuração utilizada para a medição de pressão, com diversos acessórios conectados aos sensores, optou-se por calibrar também o coeficiente de perda de carga localizada, visto que resultados preliminares demonstraram sua grande influência na medição de pressão.

Utilizando o software EPANET (Rossman, 1999) em conjunto com o Matlab, através da biblioteca criada por Elíades *et al.* (2006), a rugosidade e o coeficiente de perda de carga localizada de todas as tubulações do modelo foram ajustados entre os seguintes valores: 0,001 e 0,5 mm para a rugosidade, e 0 a 10 para o coeficiente de perda de carga localizada. Simulações para vazões de 3,2 L/s e 3,9 L/s foram feitas no EPANET para adquirir a pressão simulada (p_{sim}). Este valor é comparado com as medições feitas (p_{mon}), e o processo se repete até que a função objetivo (Equação 1) seja minimizada. Os valores de vazão dos ensaios foram adotados para que diferenças nas medições de pressão dos nós fossem observadas, uma vez que, devido ao pequeno porte da rede, para vazões menores a perda de carga é quase nula, fazendo com que a diferença de pressão dos nós seja próxima da precisão dos sensores.

$$FO = \sum_{i=1}^{n_p} |p_{mon} - p_{sim}| \tag{1}$$

em que *FO* é a função objetivo a ser minimizada, n_p é o número de medidas de pressão realizadas, p_{mon} é o valor da pressão medida e p_{sim} é o valor da pressão simulada.

Para cada condição de vazão, 16 medições de pressão estão disponíveis, uma vez que todos os nós possuem sensores instalados, totalizando 32 valores que podem ser utilizados no cálculo da função objetivo pela Equação 1. Entretanto, em sistemas reais o monitoramento completo da rede de distribuição não é viável. Assim, para avaliar as diferenças no resultado da calibração para diferentes graus de monitoramento, foram considerados o uso de 1 a 16 sensores no processo. Para cada caso 100 calibrações foram feitas, e os sensores utilizados para cálculo da função objetivo foram escolhidos de forma aleatória.

Particle Swarm Optimization

A minimização da função objetivo apresentada na Equação 1 é feita através do algoritmo *Particle Swarm Optimization* (PSO). Este algoritmo é baseado no comportamento de bandos de pássaros em busca por comida, onde a experiência individual e coletiva são fundamentais para o sucesso (Eberhart e Kennedy, 1995). De forma geral, cada pássaro (partícula) inicia sua busca em um

local aleatório *X*, com uma determinada velocidade *V* também aleatória. Sua proximidade com relação ao alimento *P*, representada pelo valor da função objetivo, é avaliada, assim como a proximidade das demais partículas do grupo para que sua nova trajetória seja ajustada em direção à um melhor local. Matematicamente o processo é representado pelas Equações 2 e 3. Além do processo de busca descrito, os coeficientes aleatórios k_1 e k_2, com valores entre 0 e 1, são utilizados para garantir maior abrangência da exploração.

$$V_{i+1} = \omega . V_i + c_1 . k_1 (P - X_i) + c_2 . k_2 (P_g - X_i) \quad (2)$$

$$X_{i+1} = X_i + V_{i+1} \quad (3)$$

em que ω é o coeficiente de inércia, c_1 o coeficiente cognitivo, *P* a melhor posição já ocupada pela partícula, c_2 o coeficiente social e P_g a melhor posição já ocupada por qualquer partícula do grupo. Em todos os casos foram utilizadas 50 partículas e um número máximo de 500 iterações, com o coeficiente de inércia dinâmico ao longo das iterações, variando seu valor entre 0,1 e 1,1, e os coeficientes cognitivo e social iguais a 1,49 (Meirelles et al, 2017).

RESULTADOS

A Figura 3 apresenta os resultados do monitoramento de pressão para as duas vazões estudadas. A diferença entre a pressão medida nos nós se deve exclusivamente às perdas de carga, uma vez que todos se encontram na mesma elevação. Para a vazão de 3,2 L/s o desvio padrão foi de 5,5 %, enquanto que para a vazão de 3,9 L/s este valor subiu para 16,7 %. Comparando os dois casos, a redução média da pressão foi de 26,5 %. Estas diferenças indicam que a perda de carga localizada existente nos pontos de medição é relevante no modelo.

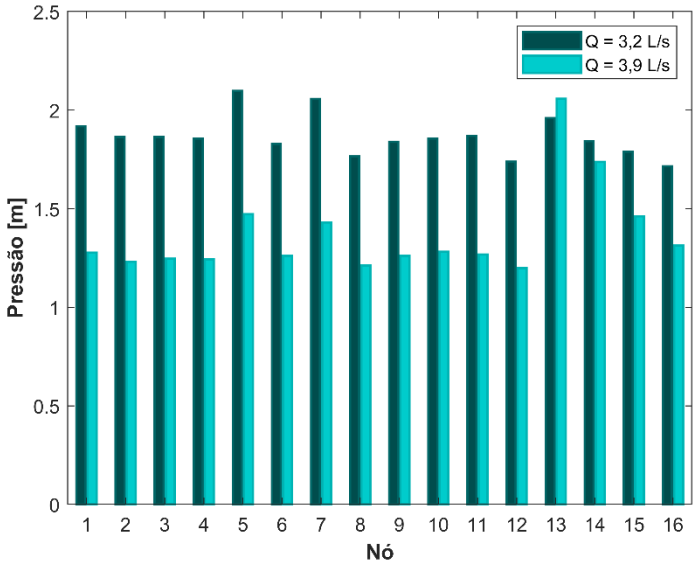

Figura 3 – Resultados da coleta de dados para as vazões de 3,2 L/s e 3,9 L/s

A Figura 4 apresenta os valores obtidos para a função objetivo em cada um dos cenários de monitoramento. Nota-se que o valor absoluto aumenta de acordo com o número de sensores, uma vez que há mais dados a serem confrontados, mas que o erro relativo (por sensor) se mantém aproximadamente constante. A grande diferença observada é a maior consistência dos resultados com o maior grau de monitoramento, ou seja, há uma maior confiabilidade dos resultados obtidos pela calibração nestes cenários.

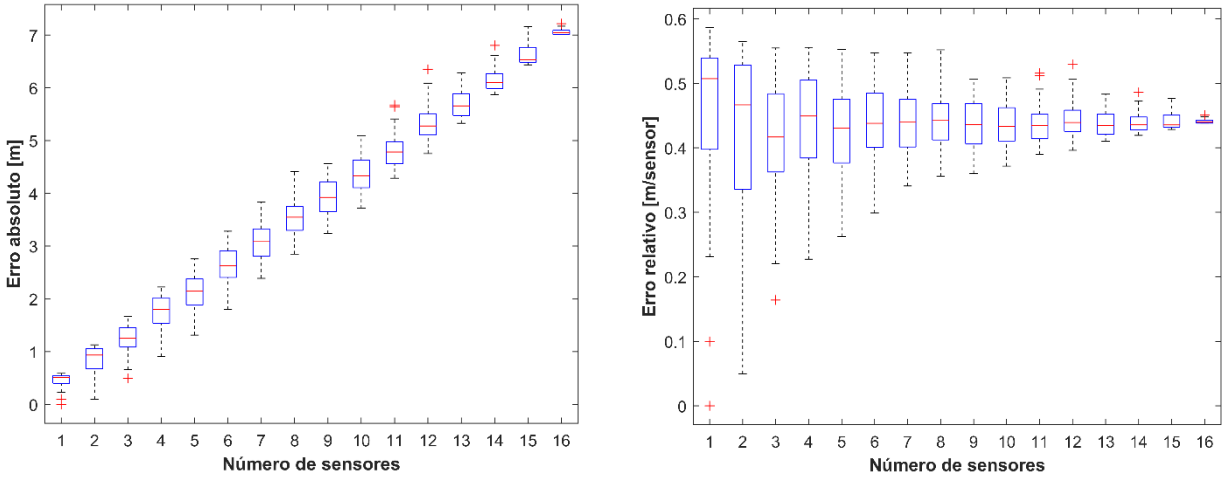

(a) **(b)**

Figura 4 – Valor da função objetivo para cada cenário de monitoramento: a) Valor absoluto; b) Valor relativo

Com relação aos valores obtidos para os parâmetros calibrados, observa-se pela Figura 5 que tanto a rugosidade quanto o coeficiente de perda de carga localizada não sofreram grandes alterações

com o aumento do monitoramento. Entretanto, quando os valores de cada tubulação são comparados, conforme ilustra a Figura 6, nota-se novamente a maior consistência dos resultados obtidos com o maior monitoramento, com menor variabilidade dos valores e menos *outliers*. Por fim, nota-se que na rede LENHS as tubulações 3 e 7 aparentam estar em piores condições, pois consistentemente apresentaram maiores valores de rugosidade, sendo possível identificar este comportamento para qualquer grau de monitoramento.

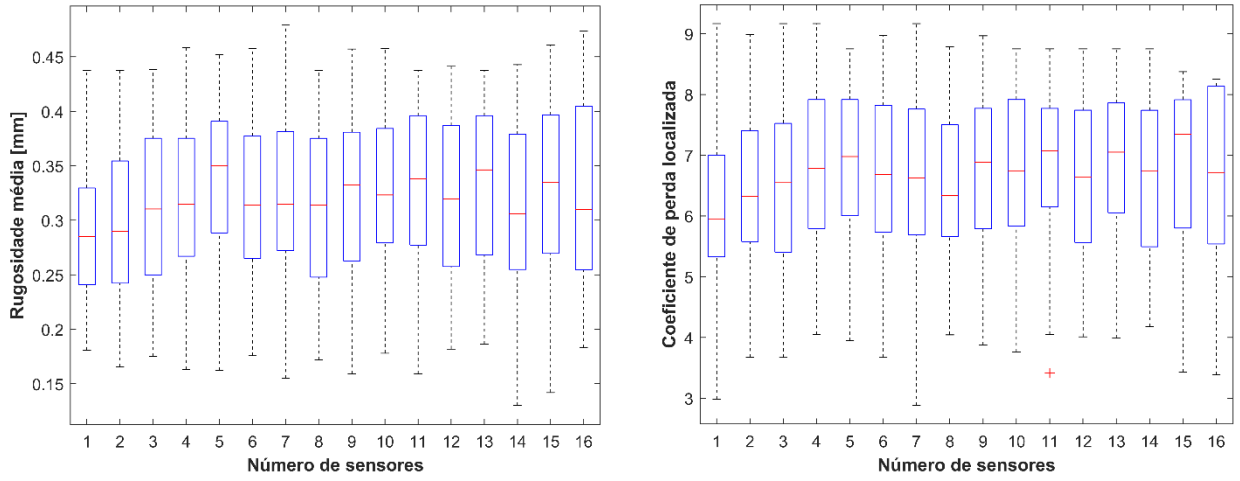

(a) **(b)**

Figura 5 – Valor médio dos parâmetros calibrados para cada cenário de monitoramento: a) Rugosidade; b) Coeficiente de perda localizada

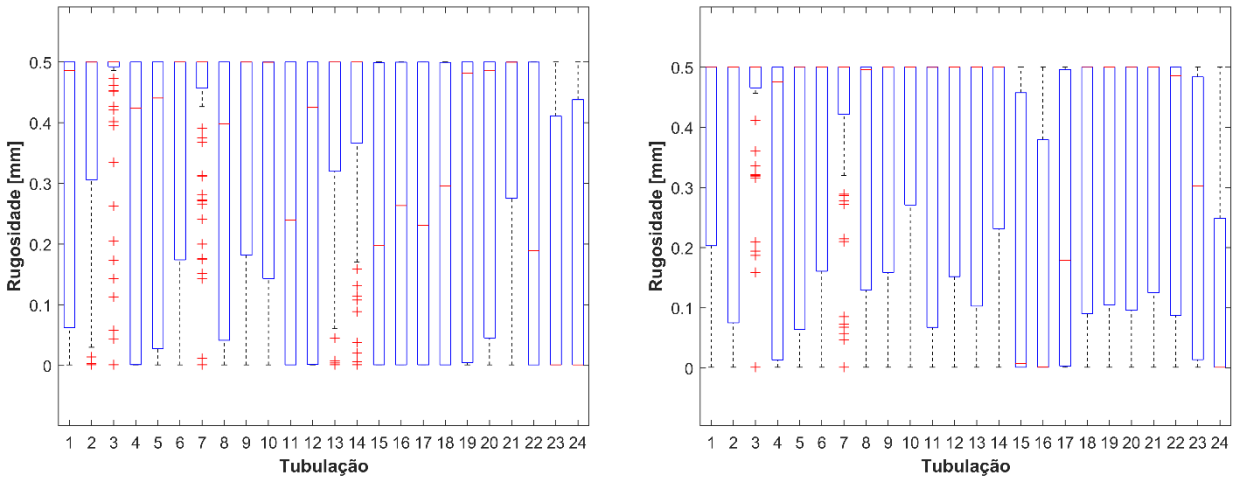

(a) **(b)**

Figura 6 – Rugosidade de cada tubulação para diferentes cenários de monitoramento: a) 3 sensores; b) 16 sensores

CONCLUSÕES

O trabalho comparou os resultados de calibração de diferentes graus de monitoramento de uma rede de distribuição de água no processo de calibração. A rugosidade e o coeficiente de perda de carga localizada de cada tubulação foram os parâmetros a serem ajustados no modelo. Os resultados obtidos mostram que o valor destes parâmetros não variou significativamente com o aumento do monitoramento. Entretanto, com um número maior de sensores, os resultados foram mais consistentes, apresentando menor variabilidade e menos *outliers*. Em redes maiores e mais complexas esta diferença pode se elevar, uma vez que o espaço de busca aumenta significativamente o esforço do processo de otimização. Por fim, observou-se valores de rugosidade consistentemente maiores nas tubulações 3 e 7 da rede LENHS, indicando uma maior deterioração ou problemas nas válvulas destes trechos. Ambos os cenários com baixo e alto grau de monitoramento foram capazes de identificar este comportamento.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro dado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) para o desenvolvimento desta pesquisa através da implementação da bolsa de produtividade PQ-2, Chamada CNPQ Nº 04/2021. Os autores também agradecem ao apoio financeiro da FAPEMIG ao projeto APQ-04483-18 em que este trabalho foi desenvolvido, financiado no âmbito da Chamada 503/2018, CONFAP Water JPI 2017.

REFERÊNCIAS

BRENTAN, B., MEIRELLES, G., LUVIZOTTO Jr, E., & IZQUIERDO, J. (2018). Joint operation of pressure-reducing valves and pumps for improving the efficiency of water distribution systems. *Journal of Water Resources Planning and Management*, *144*(9), 04018055.

EBERHART, R., & KENNEDY, J. (1995, November). *Particle swarm optimization*. Anais do IEEE international conference on neural networks (Vol. 4, pp. 1942-1948).

ELIADES, D. G., KYRIAKOU, M., VRACHIMIS, S., & POLYCARPOU, M. M. (2016). *EPANET-MATLAB toolkit: An open-source software for interfacing EPANET with MATLAB*. Anais 14th international conference on computing and control for the water industry (CCWI) (Vol. 8).

LAMBROU, T. P., ANASTASIOU, C. C., PANAYIOTOU, C. G., & POLYCARPOU, M. M. (2014). *A low-cost sensor network for real-time monitoring and contamination detection in drinking water distribution systems*. IEEE sensors journal, 14(8), 2765-2772.

MALA-JETMAROVA, H., SULTANOVA, N., & SAVIC, D. (2017). *Lost in optimisation of water distribution systems? A literature review of system operation*. Environmental modelling & software, 93, 209-254.

MANZI, D., BRENTAN, B., MEIRELLES, G., IZQUIERDO, J., & LUVIZOTTO, E. (2019). *Pattern recognition and clustering of transient pressure signals for burst location*. Water, 11(11), 2279.

MEIRELLES, G., MANZI, D., BRENTAN, B., GOULART, T., & LUVIZOTTO, E. (2017). *Calibration model for water distribution network using pressures estimated by artificial neural networks*. Water Resources Management, 31(13), 4339-4351.

MORAES, D. S.; STERLE, L.; ROCLAWSKI, H.; KRATZIG, T.; DEWALS, B.; VERCOUTER, L.; MEIRELLES, G. & SALIBA, A. P. M. *Low-cost monitoring for water distribution systems*. Anais do XXIV Simpósio Brasileiro de Recursos Hídricos, 2021, Belo Horizonte.

ROSSMAN, L. A. (1999). *The EPANET programmer's toolkit for analysis of water distribution systems*. Anais do WRPMD'99: Preparing for the 21st Century (pp. 1-10).

SAVIC, D. A., KAPELAN, Z. S., & JONKERGOUW, P. M. (2009). *Quo vadis water distribution model calibration?*. Urban Water Journal, *6*(1), 3-22.

VERMESAN, O., FRIESS, P., GUILLEMIN, P., SUNDMAEKER, H., EISENHAUER, M., MOESSNER, K., & COUSIN, P. (2013). Internet of things strategic research and innovation agenda. *Internet of things: converging technologies for smart environments and integrated ecosystems*, 7-152.

WÉBER, R., & HŐS, C. (2020). Efficient technique for pipe roughness calibration and sensor placement for water distribution systems. *Journal of Water Resources Planning and Management*, *146*(1), 04019070.

YAZDANI, A., OTOO, R. A., & JEFFREY, P. (2011). *Resilience enhancing expansion strategies for water distribution systems: A network theory approach*. Environmental Modelling & Software, 26(12), 1574-1582.