

Desenvolvimento de um modelo híbrido Migha-RNA para calibração de rugosidades absolutas em redes de distribuição de água

Development of a hybrid Migha-ANN model for calibration of absolute roughness in water distribution networks

David Lopes de Sousa^{1*} , Alessandro de Araújo Bezerra² , Marco Aurélio Holanda de Castro¹ ,
Guilherme Costa Rodrigues Neto¹ , Rafael Brito Aguiar de Araujo¹ 

RESUMO

Este trabalho teve como objetivo desenvolver um novo método híbrido de calibração de rugosidades absolutas em redes de distribuição de água, com base na combinação do método iterativo do gradiente hidráulico alternativo (Migha) com uma rede neural artificial (RNA) do tipo Perceptron Multicamadas. Foram testadas diferentes configurações para o modelo, em vários cenários que diferiam quanto ao número de pressões observadas utilizadas. Os resultados encontrados sugerem que a combinação dos métodos foi favorável à calibração das rugosidades, com erros absolutos médios inferiores a 0,016 mm no modelo que calculava apenas um valor por material para o parâmetro. A boa *performance* também ficou evidente quando analisadas as pressões e vazões retornadas pela simulação da rede calibrada, as quais apresentaram erros relativos médios de 0,12 e 0,36%, respectivamente, no cenário com 14% dos nós com pressões conhecidas, erros consideravelmente inferiores àqueles obtidos pela configuração inicial da rede e pelo uso exclusivo do Migha.

Palavras-chave: redes de distribuição de água; calibração; rugosidades; método iterativo do gradiente hidráulico alternativo; rede neural artificial.

ABSTRACT

This work aimed to develop a new hybrid method for the calibration of absolute roughness in water distribution networks, starting from the combination of the Alternative Hydraulic Gradient Iterative Method (Migha) with a Multilayer Perceptron Artificial Neural Network (ANN). Different configurations were tested for the model, in different scenarios that differed in the number of observed pressures used. The results found suggest that the combination of methods was favorable to roughness calibration, with mean absolute errors lower than 0.016 mm in the model that calculated only one value per material for the parameter. The good performance was also evident when analyzing the pressures and flows returned by the calibrated network simulation, which showed average relative errors of 0.12 and 0.36%, respectively, in the scenario with 14% of nodes with known pressures, errors considerably lower than those obtained by the initial configuration of the network and the exclusive use of Migha.

Keywords: water distribution networks; calibration; roughness; alternative hydraulic gradient iterative method; artificial neural network.

INTRODUÇÃO

A calibração do modelo hidráulico de uma rede de distribuição de água (RDA) é necessária para compatibilizar as vazões e pressões calculadas pelo modelo com as obtidas em campo, o que é uma tarefa desafiadora, levando-se em conta a grande quantidade de parâmetros envolvidos (JADHAO; GUPTA, 2018). Uma metodologia de calibração empregada em RDAs é o método iterativo do gradiente hidráulico alternativo (Migha). O algoritmo desse método foi desenvolvido inicialmente por Guo e Zhang (1994), para a

calibração da transmissividade hidráulica em aquíferos subterrâneos, sendo posteriormente adaptado por Schuster e Araújo (2004) e mais tarde por diversos autores para o seu uso em sistemas de abastecimento de água. No emprego em RDAs, pode-se destacar o uso do Migha no ajuste da rugosidade absoluta das tubulações (BEZERRA; CASTRO; ARAÚJO, 2017; SOUSA; BEZERRA; CASTRO, 2021), na análise dos consumos nodais e vazamentos (ARAÚJO; BEZERRA; CASTRO, 2021) e na atualização do coeficiente de decaimento de cloro (PEREIRA; CASTRO, 2013).

¹Universidade Federal do Ceará – Fortaleza (CE), Brasil.

²Universidade Federal do Piauí – Teresina (PI), Brasil.

*Autor correspondente: david.lopes2@hotmail.com

Conflitos de interesse: os autores declaram não haver conflitos de interesse.

Financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Recebido: 16/06/2022 – Aceito: 12/09/2022 – Reg. ABES: 20220151

Outra estratégia empregada na modelagem de RDAs é a aplicação de algoritmos de aprendizado de máquina, tais como as redes neurais artificiais (RNAs), máquina de vetores de suporte, algoritmos genéticos e sistemas *fuzzy* (SALVINO; CARVALHO; GOMES, 2015; GIRALDO-GONZÁLEZ; RODRÍGUEZ, 2020). Pela sua grande capacidade de reconhecer padrões, quando estimulados com dados, esses métodos têm sido amplamente empregados na localização de rompimentos nas tubulações e na detecção de áreas de vazamento (CAPELO *et al.*, 2021), na calibração de demandas (PEREA *et al.*, 2021) e na análise de parâmetros de qualidade (ZOUNEMAT-KERMANI *et al.*, 2018).

Uma alternativa atraente que vem sendo empregada na literatura na calibração de processos multivariados e não lineares é o uso das RNAs, com destaque para o tipo Perceptron Multicamadas (PMC), arquitetura bastante popular nesses estudos (CHIAPPINI *et al.*, 2020). As RNAs apresentam-se como estruturas inspiradas nas redes neurais do cérebro humano, contendo vários nós conectados, em várias camadas — no caso do PMC —, chamados neurônios artificiais. Estes, por sua vez, são responsáveis por receber informações externas e propagá-las para outros neurônios artificiais, transmitindo dados de forma não linear. Esse método conta com diversos algoritmos de aprendizagem que aprimoram os resultados obtidos após o estímulo com informações externas (CHEN; LU; HE, 2020).

Uma questão relevante na modelagem e calibração de sistemas de abastecimento de água é o envelhecimento das tubulações. Especialmente em RDAs feitas de tubos de aço e ferro fundido, as condições do fluxo hidráulico podem se deteriorar com o passar dos anos. Esse fenômeno ocorre por causa da incrustação das paredes da tubulação ocasionada por sedimentos precipitados da água, ou mesmo como um produto da própria corrosão da tubulação. Isso acarreta redução e deformação da área da seção transversal das tubulações, assim como aumento da rugosidade com o passar dos anos (WICHOWSKI *et al.*, 2021). Essa modificação na rugosidade dificulta a representação da rede instalada, já que esse parâmetro é um dado de entrada para realizar as simulações hidráulicas.

Este trabalho teve como objetivo apresentar uma nova metodologia de calibração da rugosidade absoluta: um método híbrido realizado em duas etapas, combinando o algoritmo do Migha com uma RNA, na tentativa de otimizar o processo de calibração. A importância do aperfeiçoamento desses métodos reside na necessidade de se obter modelos de RDAs confiáveis mesmo em circunstâncias com baixa quantidade de dados observados, situação bastante corriqueira em vários sistemas de abastecimento.

METODOLOGIA

Etapa do Migha

Bezerra, Castro e Araújo (2017) propuseram a utilização do Migha na calibração do fator de atrito e posterior cálculo das rugosidades, em que os valores ajustados para o fator de atrito são calculados a cada iteração pela Equação 1, e a respectiva rugosidade absoluta da tubulação é calculada posteriormente por meio da Equação 2, obtida isolando-se esse parâmetro na fórmula da perda de carga de Swamee-Jain.

$$f_j^{i+1} = f_j^i \left(\frac{|\nabla H_{o_j}|}{|\nabla H_{c_j}|} \right) \quad (1)$$

$$\varepsilon_j^{i+1} = \frac{3,7D_j \times \left[(\text{Rey}_j^i)^{0,9} - 5,74 \times 10^{0,5/\sqrt{f_j^{i+1}}} \right]}{(\text{Rey}_j^i)^{0,9} \times 10^{0,5/\sqrt{f_j^{i+1}}}} \quad (2)$$

Em que:

f: fator de atrito;

∇H_o : gradiente hidráulico, ou perda de carga unitária, obtido pela simulação da rede com dados observados;

∇H_c : gradiente hidráulico obtido pela simulação da rede, sem dados observados;

ε : rugosidade absoluta (m);

D: diâmetro interno da tubulação (m);

Rey: número de Reynolds;

i: iteração;

j: trecho.

Essa metodologia utiliza como simulador hidráulico a rotina do Epanet, obtendo a cada iteração os valores de ∇H_c , retornados pela simulação da então chamada rede calculada. Nessa rede, rugosidades iniciais arbitrárias são atribuídas aos trechos. Esse parâmetro é então atualizado pelas Equações 1 e 2 no decorrer do processo. Os valores de ∇H_o são obtidos pela simulação de uma segunda rede, a qual o método denomina de rede observada. Para a criação desta, o Migha utiliza reservatórios de nível fixo fictícios para forçar os nós da rede a alcançar as pressões medidas em campo, ou adquiridas de uma rede gabarito fictícia. Para isso, são criados trechos que conectam o nó com a pressão medida ao reservatório, que deve possuir carga hidráulica igual à do nó de pressão conhecida. Já o trecho deve apresentar comprimento igual a 1 mm e diâmetro igual a 3.000 mm, de modo a não resultar em perdas consideráveis (SOUSA; BEZERRA; CASTRO, 2021).

O método emprega como função objetivo a ser minimizada a Equação 3, proposta por Rocha, Castro e Araújo (2009). Desse modo, o critério de parada do processo de calibração pode ser tanto um número limitado de iterações como um valor mínimo a ser alcançado pela Equação 3.

$$f_{obj} = \sum_{nt} (\nabla H_o - \nabla H_c)^2 \quad (3)$$

Em Sousa, Bezerra e Castro (2021), foram testadas diferentes funções objetivo, mas foi observado que isso não afetou de forma relevante o resultado final da calibração. Constatando-se que o Migha tende a estabilizar rapidamente e também com o intuito de padronizar o método, os autores optaram por utilizar como critério de parada o número de 100 iterações. Outro ponto relevante quanto à convergência do método está no fato de que a solução retornada pelo Migha não é, necessariamente, a última iteração realizada, mas sim aquela que apresentou o menor valor calculado para a função objetivo. Em muitos testes realizados foi visto que as primeiras iterações apresentavam os melhores resultados, por isso o limite de 100 foi estabelecido, o que também contribuiu para manter baixo o tempo de processamento da calibração, uma das qualidades desse método.

Uma nova sub-rotina, de Sousa, Bezerra e Castro (2021), propõe uma metodologia que uniformiza as rugosidades calibradas dos trechos que possuem o

mesmo material, ainda zelando por encontrar resultados de pressão e vazão que se aproximam da rede real. Essa adaptação, além de contribuir com melhores resultados, retornam valores de rugosidade mais verossímeis, visto que é plausível que tubulações de um mesmo material apresentem valores semelhantes para esse parâmetro, desde que sejam de um mesmo fabricante e tenham a mesma idade. Nessa sub-rotina de uniformização, ao fim de cada iteração, as rugosidades absolutas calculadas pela Equação 2 são submetidas a uma verificação, em que para cada conjunto de materiais é averiguada a existência de valores aberrantes para aquela família de tubulações. Ou seja, para cada material haverá uma lista de rugosidades calculadas, em que é investigada a existência de valores que se distanciam dos demais do mesmo grupo. A Figura 1 esquematiza a rotina de cálculo do Migha.

Etapa da rede neural artificial

Apesar da grande capacidade de reconhecer padrões de uma RNA, a construção do modelo depende de inúmeros parâmetros, o que tende a dificultar sua aplicação. Na definição da arquitetura de um PMC, devem-se determinar:

- a quantidade de camadas intermediárias (n_c);
- o número de neurônios em cada camada (n_n);
- a função de ativação ($g(\cdot)$), responsável por limitar o valor de saída do neurônio em um intervalo de valores concebíveis;
- a distribuição dos pesos sinápticos da primeira iteração (w_i);
- limiares de ativação (θ);
- método de aprendizagem da rede;
- número de épocas (e), ou seja, a quantidade de vezes que será utilizada a totalidade dos dados da amostra no treinamento;
- tamanho dos lotes de aprendizagem (l);
- taxa de aprendizagem (η);
- *momentum* (m);
- função de custo ($E(\cdot)$), utilizada no critério de parada.

Desse modo, a aplicação dessa metodologia na modelagem de sistemas de abastecimento de água costuma empregar uma abordagem individualizada, em que se procura encontrar a melhor configuração de uma RNA para dada RDA.

No entanto, na intenção de estabelecer uma rotina única de calibração que sirva para diferentes redes, a maioria desses parâmetros foi adotada como fixa neste trabalho, conforme Tabela 1, com exceção do número de neurônios em cada camada, que foi associado com o número de nós da RDA.

Para a construção das RNAs utilizadas aqui, foi utilizada a biblioteca de programação DeepLearning4J (DL4J), uma biblioteca de aprendizagem profunda lançada pela Skymind em junho de 2014, distribuída com código aberto em linguagem Java (WANG *et al.*, 2019). Entre as inúmeras funcionalidades das classes disponíveis, encontra-se a possibilidade de se construir um PMC atribuindo os parâmetros de arquitetura da rede para posteriormente treiná-la, obtendo-se um modelo não linear capaz de prever dado comportamento, correlacionando dados de entrada e saída.

Um modelo de calibração das rugosidades de uma RDA pode ser construído utilizando-se apenas um PMC do seguinte modo: valendo-se do Epanet como simulador hidráulico, simula-se a RDA numerosas vezes, variando as rugosidades dos trechos. Para cada simulação, anotam-se as rugosidades empregadas e as respectivas pressões retornadas. Em seguida, esses dados podem ser utilizados na ordem contrária para realizar o treinamento do PMC, admitindo-se as pressões como dados de entrada e as rugosidades como repostas, obtendo-se por fim um modelo de regressão baseado em uma RNA que correlaciona as pressões e as rugosidades.

Apesar da grande capacidade de reconhecer padrões de uma RNA, há diversos fatores que dificultam a criação de uma metodologia única para o seu emprego em calibrações de RDAs. Um desses fatores é o grande número de parâmetros,

Tabela 1 – Parâmetros adotados no Perceptron Multicamadas.

n_n	n_c	$g(\cdot)$	W_i e θ	Método de aprendizagem
$2n_{nd}$	2	<i>LeakyReLU</i>	Randômicos	SGD
e	l	η	m	$E(\cdot)$
1.000	50	0,01	0,9	MSE

n_n : número de neurônios em cada camada; n_c : quantidade de camadas intermediárias da rna; $g(\cdot)$: função de ativação; W_i : pesos sinápticos da primeira iteração; θ : limiar de ativação; n_{nd} : número de nós da rede de distribuição de água; SGD: *stochastic gradient descent*; MSE: *mean squared error*.

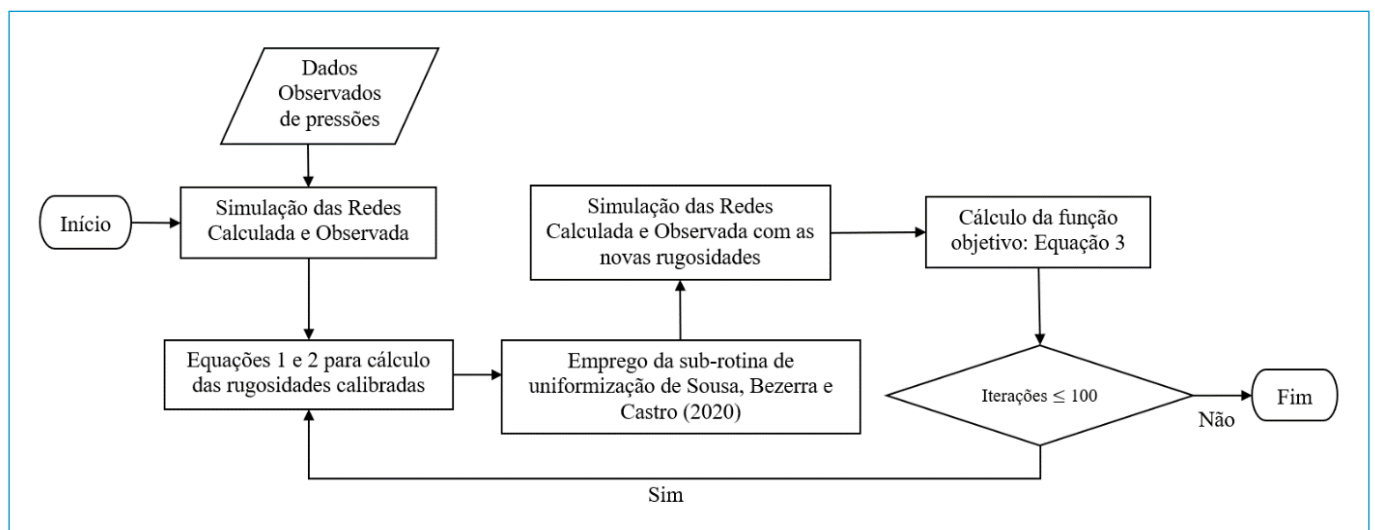


Figura 1 - Fluxograma do método iterativo do gradiente hidráulico alternativo.

como já mencionado. Outro fator decisivo relaciona-se com os dados utilizados no treinamento. Para a metodologia apresentada, a RDA deve ser simulada várias vezes para se obter dados para o treinamento do PMC, variando-se as rugosidades, no entanto a faixa de variação das rugosidades utilizada nesse treinamento é um dos fatores que mais influenciam na capacidade do PMC de retornar bons resultados, devendo ser escolhida com cautela. Outros fatores relevantes são a dificuldade apresentada pelo modelo quando este tem muitas saídas, como quando se quer calibrar todos os trechos de uma RDA individualmente, e também a dificuldade quando ele possui poucas entradas, como quando há poucos dados de pressão observados.

A par das dificuldades impostas na aplicação das metodologias citadas, este trabalho descreve um método híbrido que procura reunir as vantagens do Migha e do modelo de calibração com PMC, tentando contornar os fatores que foram citados e que dificultam na obtenção de valores de rugosidades mais próximos dos reais, conforme segue.

Método híbrido

A metodologia desenvolvida neste trabalho emprega, em um primeiro momento, o Migha, de modo a obter a calibração prévia da RDA. Essa primeira etapa já produz valores de rugosidade calibrados para todos os trechos, bem como valores de pressão obtidos para todos os nós após uma simulação dessa configuração calibrada. Em um segundo momento, utilizam-se as rugosidades encontradas pelo Migha para criar a faixa de variação que será empregada para gerar os dados do treinamento do PMC. Neste estudo, usaram-se valores que variam linearmente entre o maior valor de rugosidade encontrado para o material, acrescido de 25%, e o menor valor encontrado para o material, reduzido de 25%. Esse acréscimo e redução para o estabelecimento da faixa facilitam o PMC a encontrar valores maiores ou menores do que os retornados pelo Migha.

Com a faixa de variação estabelecida, é possível gerar os dados necessários para o ajuste do modelo PMC, por intermédio de repetidas simulações para as diferentes configurações de rugosidade. Neste trabalho, foi estabelecido o tamanho de 650 configurações de RDA para treinamento e de 350 para teste. Desse modo, como são utilizados os dados do treinamento para o ajuste do PMC e admitindo-se que o número de épocas é igual a 1.000 e o tamanho dos lotes de treinamento é 50, são realizadas ao todo 13 mil iterações, ou seja, 13 mil ajustes nos pesos sinápticos, para cada calibração.

Para a determinação do PMC ideal, empregou-se a rotina Early Stopping, presente na biblioteca do DL4J. Essa rotina consiste em uma verificação de desempenho do modelo, ao fim de cada época, no conjunto de dados reservados para o teste. Se, ao final de dada época, o atual PMC superar o modelo anterior, será salva uma cópia do PMC dessa época. Desse modo, ao final do treinamento, 1.000 configurações terão sido testadas, sendo o modelo final aquele com melhor desempenho no conjunto de testes. Essa metodologia diminui a possibilidade de um sobreajuste do modelo aos dados de treinamento.

Por fim, após a obtenção do melhor modelo PMC, é realizada uma nova calibração, utilizando os dados observados de pressões como entrada. Para verificar possíveis soluções para as dificuldades mencionadas previamente, foram ainda verificadas e comparadas diferentes formas de se fazer essa calibração, admitindo-se a possibilidade de se considerar as pressões obtidas após o Migha como dados de entrada, visto que esse método já retorna bons valores para essa variável hidráulica (BEZERRA; CASTRO; ARAÚJO, 2017;

SOUSA; BEZERRA; CASTRO, 2021). Além disso, também foram comparados os resultados alcançados calibrando-se individualmente os trechos com aqueles das calibrações que admitem apenas um valor de rugosidade por material. Por fim, também foram utilizados na comparação os valores obtidos somente pelo Migha. Desse modo, a Tabela 2 traz os diferentes tipos de calibração realizados neste estudo.

O fluxograma da Figura 2 corresponde às etapas do método híbrido desenvolvido.

Portanto, a convergência do método dá-se pela escolha da melhor configuração do PMC pela rotina Early Stopping, mencionada anteriormente. É importante notar que o método híbrido foi desenvolvido para calibrar qualquer tipo de rede, independentemente do tamanho. Para isso, a rotina foi construída de modo a adaptar o PMC conforme o número de nós da rede, alterando-se o número de neurônios nas camadas intermediárias. Relacionar o número de neurônios com o número de nós da rede é uma tentativa de fazer com que o modelo compreenda a complexidade e a não linearidade do cálculo das rugosidades em redes de maior porte.

Rede Sousa

Com o intuito de testar as metodologias propostas, foi empregada nos testes deste trabalho a Rede Sousa (SOUSA, 2020). Trata-se de uma rede fictícia em que se conhecem as rugosidades de todos os trechos. A Figura 3 apresenta o desenho da Rede Sousa com a identificação dos trechos.

Na Rede Sousa, admite-se a existência de uma variação da rugosidade absoluta em trechos de mesmo material. As rugosidades absolutas dos trechos de policloreto de vinila (PVC) foram definidas entre valores de 0,0015 a 0,01 mm. Para o ferro fundido, as rugosidades foram determinadas variando de 0,25 a 0,50 mm. Os trechos possuem 100 m de comprimento, com exceção do trecho 85, que possui 50 m, e diâmetros que variam de 200 a 50 mm, a depender da vazão. Os nós possuem cotas variando de 223 a 189 m e consumos de 0,63, 0,47 e 0,31 L·s⁻¹, para os nós intermediários, de extremidade e de canto, respectivamente.

RESULTADOS E DISCUSSÃO

Para a análise da *performance* dos diferentes tipos de calibração testados, foram criados diferentes cenários, variando-se o número de pressões observadas. Em uma primeira abordagem, foram consideradas sete pressões conhecidas (14% dos nós), em nós espalhados pela rede. Em seguida, os métodos foram reempregados, admitindo-se 13 (27%) e 25 (51%) nós com dados observados. Em todas as calibrações realizadas neste estudo, a configuração da Rede Sousa foi concebida com rugosidade inicial igual a 0,06 mm, para todos os trechos, independentemente do material. Essa disposição de rugosidades corresponde ao erro absoluto médio (EAM) de 0,11 mm.

Tabela 2 – Diferentes tipos de calibração testados.

	Tipos de calibração				
	1	2	3	4	5*
Por material	Sim	Sim	Não	Não	-
Pressões do Migha	Sim	Não	Sim	Não	-

Migha: método iterativo do gradiente hidráulico alternativo; *a calibração do tipo 5 corresponde apenas ao uso do Migha, sem o emprego do método híbrido.

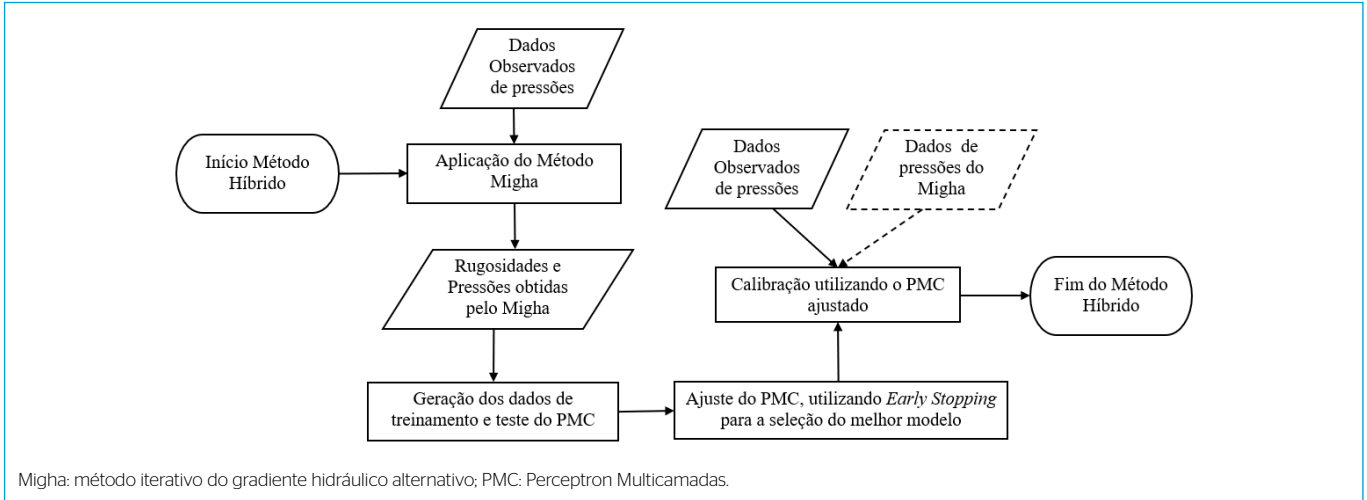


Figura 2 - Fluxograma do método híbrido.

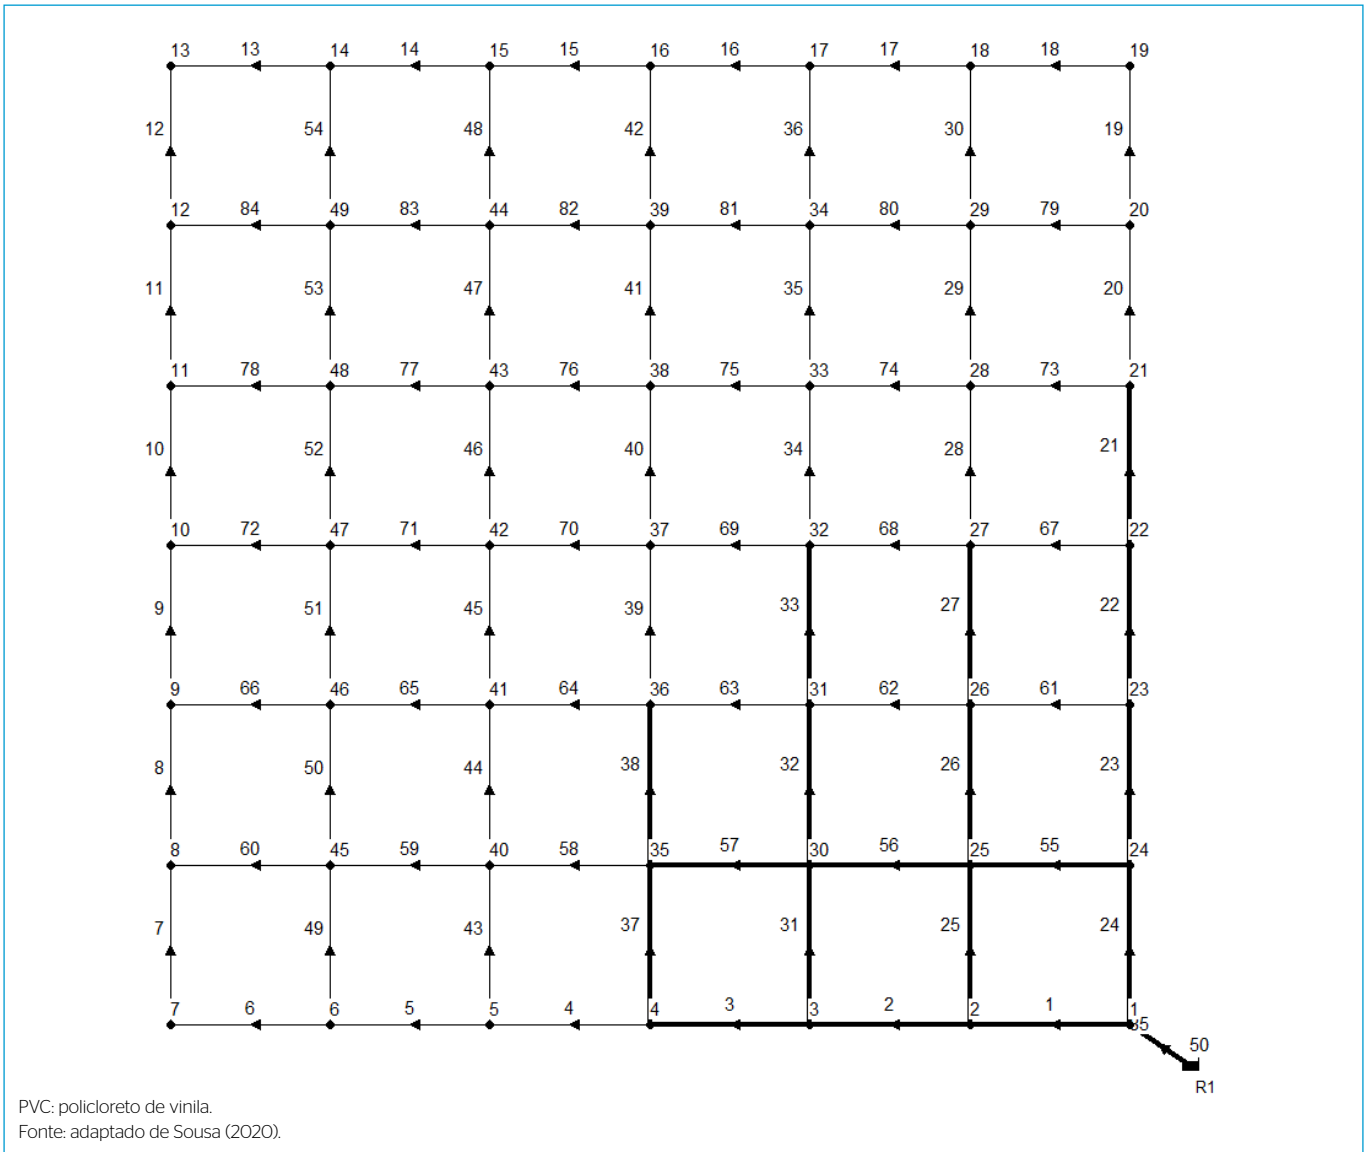


Figura 3 - Rede Sousa.

Em um primeiro cenário, considerando-se apenas sete nós com pressões conhecidas — 1, 9, 17, 25, 33, 41 e 49 —, foram obtidos os resultados apresentados nas Figuras 4 e 5, para os diferentes tipos de calibração testados.

A análise das Figuras 4 e 5 aponta para uma melhor *performance* da calibração do tipo 2, método que retorna apenas uma rugosidade calibrada para cada material, tendo sido calculado para o ferro o valor de 0,37 mm e para o PVC um valor muito baixo, de 0,00002 mm. Esses resultados conduzem a um EAM de 0,016 mm, o que demonstra que o processo corrigiu consideravelmente os valores desse parâmetro.

As Figuras 6 e 7 revelam que o aumento do número de observações empregado nos métodos de calibração aproxima os resultados do gabarito. Nesse cenário, foram utilizadas pressões conhecidas em 13 nós, sendo estes: nós 1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45 e 49.

Nota-se, principalmente para os trechos de PVC, que o acréscimo de mais dados observados aproximou significativamente os resultados obtidos pelas calibrações daqueles valores adotados como gabarito. Essa melhoria ficou mais evidente nas calibrações do tipo 3, 4 e 5, que agem atualizando os valores de rugosidade trecho a trecho na RNA, com exceção do tipo 5, que




Figura 4 - Rugosidades calibradas para os trechos de ferro, com sete dados observados.

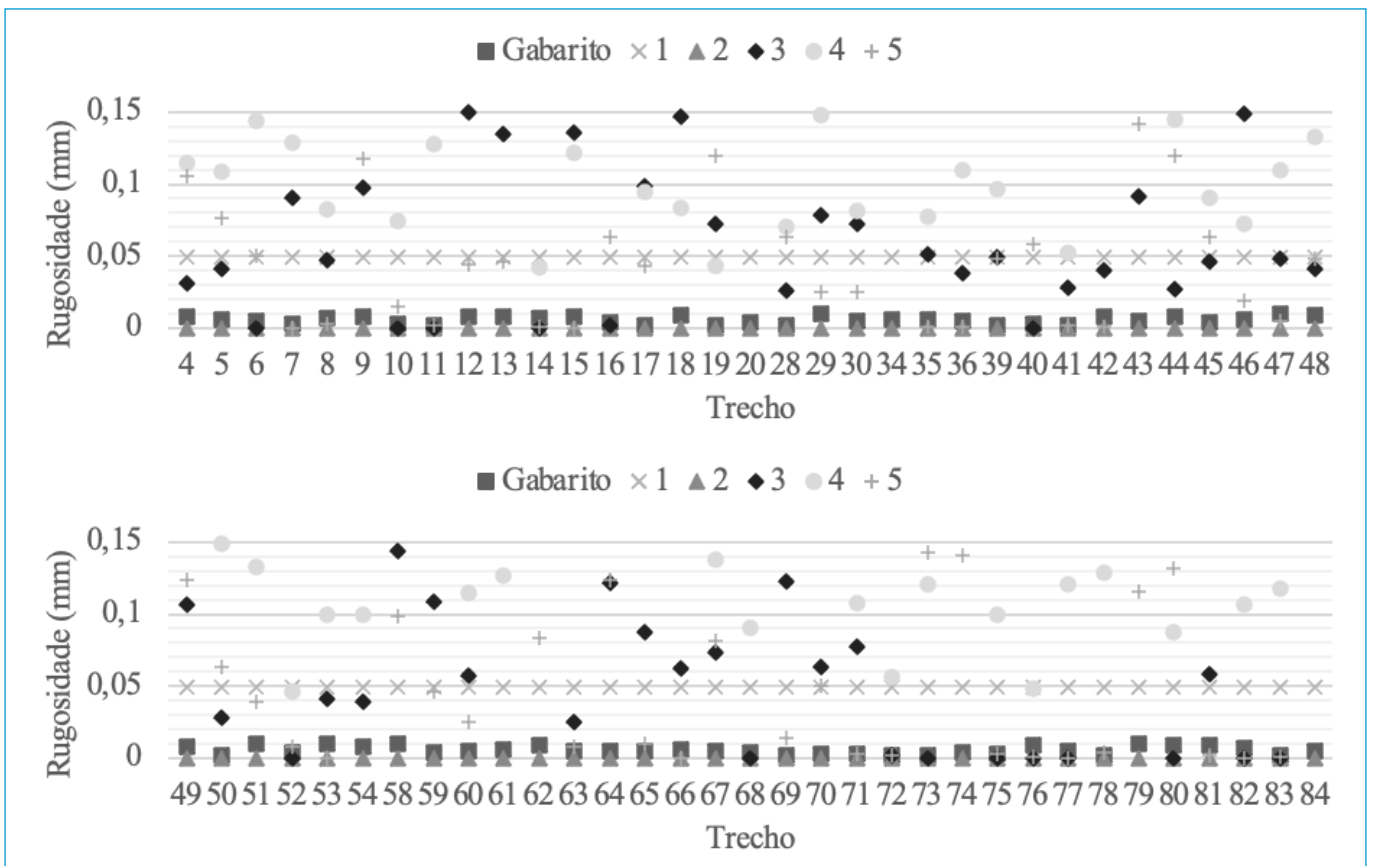


Figura 5 - Rugosidades calibradas para os trechos de policloreto de vinila, com sete dados observados.




Figura 6 - Rugosidades calibradas para os trechos de ferro, com 13 dados observados.

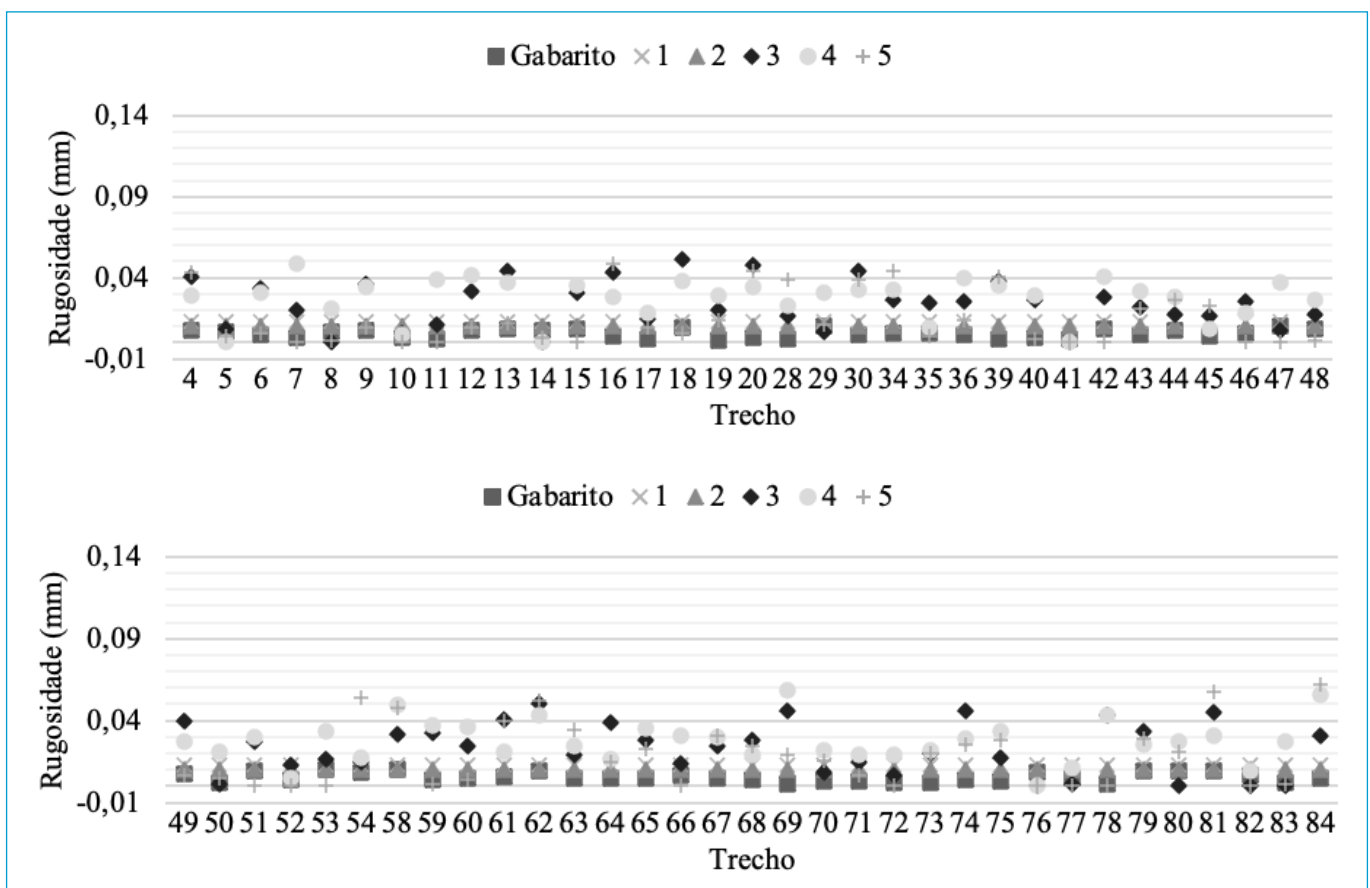


Figura 7 - Rugosidades calibradas para os trechos de policloreto de vinila, com 13 dados observados.

utiliza apenas o Migha. No entanto, para esse cenário, o método que retornou melhores resultados foi novamente o do tipo 2, que calculou o valor de 0,38 mm para as tubulações de ferro e 0,01 mm para os trechos de PVC, apresentando valor de EAM próximo àquele já obtido no cenário anterior, com sete dados observados.

Foi analisado também o melhor tipo de calibração para um cenário com 25 dados observados, ou seja, mais da metade dos nós da rede com pressões conhecidas. Para esse caso, novamente houve melhora nas calibrações

do tipo 3, 4 e 5. Apesar disso, as calibrações 1 e 2 seguiram apresentando menores erros em relação ao gabarito. A Tabela 3 apresenta os erros obtidos nesses testes.

Analisando a Tabela 3, observa-se que quase todas as calibrações reduziram o EAM, quando comparadas com a condição inicial, que estipulava valor de 0,06 mm para todos os trechos e apresentava EAM de 0,11 mm. Nota-se que as calibrações dos tipos 3 e 4 mostraram *performance* inferior ao tipo 5 — uso exclusivo do Migha. Ou seja, nesses casos, a inclusão da RNA e o emprego do

Tabela 3 - Erros absolutos médios das calibrações (mm).

	Tipos de calibração				
	1	2	3	4	5
7 observações	0,050	0,016	0,087	0,116	0,074
13 observações	0,017	0,015	0,037	0,037	0,034
25 observações	0,013	0,015	0,026	0,028	0,021

método híbrido não se justificaram. Isso ocorreu, provavelmente, pois nessas calibrações realizadas trecho a trecho o número de saídas da RNA era bastante elevado, o que dificultou no aprendizado do PMC.

Já nas calibrações que retornaram apenas um valor de rugosidade para cada material, os resultados obtidos pelo método híbrido foram superiores ao emprego único do Migha. Vê-se que, para o tipo 2, o EAM praticamente não se modificou com a inclusão de mais dados observados, pois os valores retornados pela calibração com sete observações já eram próximos dos valores médios de rugosidade dos materiais. Quanto ao uso das pressões obtidas no Migha como entradas na RNA, observou-se que estas não contribuem de forma relevante para o método, visto que a calibração do tipo 1 só apresentou o melhor resultado quando foi considerada mais da metade dos nós com dados observados, cenário pouco provável na prática.

A Tabela 4 mostra que, além de melhores valores para as rugosidades, no cenário com apenas sete observações, a calibração do tipo 2 apresenta os melhores valores para as pressões e vazões, o que já era esperado, já que essas variáveis dependem diretamente desse parâmetro hidráulico.

CONCLUSÕES

Neste trabalho, foi idealizado um método híbrido de calibração de rugosidades que combina o uso do Migha com o de uma RNA. O tempo de processamento para as calibrações, na rede em estudo, foi em média de 10 segundos para os testes que utilizaram somente o Migha e de 3 minutos para o método híbrido, em uma máquina com Intel® Core™ i5-9300 e 8 GB de memória RAM. Nos testes realizados, observou-se que esse método apresenta dificuldade quando tenta

Tabela 4 - Erros relativos médios das pressões e vazões nas calibrações com sete dados observados.

	Tipos de calibração					
	Inicial (%)	1 (%)	2 (%)	3 (%)	4 (%)	5 (%)
Pressões	3,40	0,49	0,12	0,42	0,89	0,44
Vazões	2,06	0,63	0,36	3,35	2,04	2,22

encontrar um valor para esse parâmetro por trecho, pois nessa configuração a RNA apresentava muitas saídas, o que prejudicou na fase de aprendizagem e na formação do modelo de regressão. Também foi observado que a inclusão das pressões calculadas no Migha como dados de entrada na RNA não favoreceu o método.

Por outro lado, nos testes em que foi calculado apenas um valor de rugosidade por material, o método híbrido retornou bons resultados, superando a *performance* do uso exclusivo do Migha. Nesse modelo, com 14% dos nós com pressões conhecidas, obteve-se EAM de 0,016 mm para as rugosidades, o que resultou em um erro relativo médio de 0,12 e 0,36% para as pressões e vazões calculadas pela simulação da rede calibrada.

O método híbrido proposto neste trabalho se apresenta, portanto, como uma ferramenta capaz de tornar mais plausíveis os modelos computacionais das RDAs. Como sugestões para trabalhos futuros, cabe o emprego desse modelo para calibração de outros parâmetros, como os consumos nodais e coeficientes de decaimento de cloro, bem como a adaptação desse método para simulações dinâmicas, com variação horária das demandas.

CONTRIBUIÇÕES DOS AUTORES

Sousa, D.L.: Conceituação, Curadoria de dados, Análise Formal, Investigação, Metodologia, Software, Escrita — Primeira Redação. Bezerra, A.A.: Metodologia, Investigação, Supervisão, Validação. Castro, M.A.H.: Metodologia, Administração do Projeto. Rodrigues Neto, G.C: Supervisão, Validação, Escrita — Revisão e Edição. Araujo, R.B.A.: Software, Validação, Escrita — Revisão e Edição.

REFERÊNCIAS

ARAUJO, R.B.A.; BEZERRA, A.A.; CASTRO, M.A.H. Detecção de vazamentos em redes de distribuição de água pela aplicação do método iterativo do gradiente hidráulico alternativo (MIGHA) para calibrar vazões mediante modelagem computacional. *Revista Dae*, v. 69, n. 232, p. 45-56, 2021. <https://doi.org/10.36659/dae.2021.060>

BEZERRA, A.A.; CASTRO, M.A.H.; ARAÚJO, R.S.A. Absolute roughness calculation by the friction factor calibration using the alternative hydraulic gradient iterative method on water distribution networks. *Revista Brasileira de Recursos Hídricos*, v. 22, e24, 2017. <https://doi.org/10.1590/2318-0331.021720160018>

CAPELO, M.; BRENTAN, B.; MONTEIRO, L.; COVAS, D. Near-real time burst location and sizing in water distribution systems using artificial neural networks. *Water*, v. 13, n. 13, p. 1841, 2021. <https://doi.org/10.3390/w13131841>

CHEN, H.; LU, F.; HE, B. Topographic property of backpropagation artificial neural network: from human functional connectivity network to artificial neural network. *Neurocomputing*, v. 418, p. 200-210, 2020. <https://doi.org/10.1016/j.neucom.2020.07.103>

CHIAPPINI, F.A.; ALLEGRINI, F.; GOICOECHEA, H.C.; OLIVIERI, A.C. Sensitivity for multivariate calibration based on multilayer perceptron artificial neural networks. *Analytical Chemistry*, v. 92, n. 18, p. 12265-12272, 2020. <https://doi.org/10.1021/acs.analchem.0c01863>

GIRALDO-GONZÁLEZ, M.M.; RODRÍGUEZ, J.P. Comparison of statistical and machine learning models for pipe failure modeling in water distribution networks. *Water*, v. 12, n. 4, p. 1153, 2020. <https://doi.org/10.3390/w12041153>

GUO, X.; ZHANG, C. Use of the physical feature of groundwater flow system to reduce the mathematical complexity in parameter identification - A practical and efficient automated procedure. *In: GROUNDWATER MODELING CONFERENCE*, 1994. *Proceedings...* Fort Collins, p. 111-118, 1994.

JADHAO, R.D.; GUPTA, R. Calibration of water distribution network of the Ramnagar zone in Nagpur City using online pressure and flow data. *Applied Water Science*, v. 8, 2018. <https://doi.org/10.1007/s13201-018-0672-3>

PEREA, R.G.; BALLESTEROS, R.; ORTEGA, J.F.; MORENO, M.Á. Water and energy demand forecasting in large-scale water distribution networks for irrigation using open data and machine learning algorithms. *Computers and Electronics in Agriculture*, v. 188, 106327, 2021. <https://doi.org/10.1016/j.compag.2021.106327>

PEREIRA, R.; CASTRO, M. Calibração do coeficiente de decaimento do cloro (kw) em redes de abastecimento de água utilizando o método iterativo do gradiente. *Revista Brasileira de Recursos Hídricos*, v. 18, n. 4, p. 67-76, 2013. <https://doi.org/10.21168/rbrh.v18n4.p67-76>

ROCHA, V.A.G.M.; CASTRO, M.A.H.; ARAÚJO, J.K. Calibração de rugosidade em redes de abastecimento a partir de gradientes hidráulicos através de método iterativo. *In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS*, 18., 2009. *Anais...* 2009.

SALVINO, M.M.; CARVALHO, P.S.O.; GOMES, H.P. Calibração multivariada de redes de abastecimento de água via algoritmo genético multiobjetivo. *Engenharia Sanitária e Ambiental*, v. 20, n. 3, p. 503-512, 2015. <https://doi.org/10.1590/s1413-41522015020000099484>

SCHUSTER, H.; ARAÚJO, H. Uma formulação alternativa do método iterativo de gradiente hidráulico no procedimento de calibração dos parâmetros hidrodinâmicos do sistema aquífero. *Revista Brasileira de Recursos Hídricos*, v. 9, n. 2, p. 31-37, 2004. <https://doi.org/10.21168/rbrh.v9n2.p31-37>

SOUSA, D.L. *Calibração de rugosidades em redes de distribuição de água através de uma adaptação do método iterativo do gradiente hidráulico alternativo (MIGHA)*. 163f. Dissertação (Mestrado em Engenharia Civil) - Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Recursos Hídricos, Universidade Federal do Ceará, Fortaleza, 2020.

SOUSA, D.L.; BEZERRA, A.A.; CASTRO, M.A.H. Proposta de uma nova metodologia para calibração de rugosidades em redes com diferentes materiais. *Revista Dae*, v. 69, n. 228, p. 16-33, 2021. <https://doi.org/10.36659/dae.2021.002>

WANG, Z.; LIU, K.; LI, J.; ZHU, Y.; ZHANG, Y. Various frameworks and libraries of machine learning and deep learning: a survey. *Archives of Computational Methods in Engineering*, 2019. <https://doi.org/10.1007/s11831-018-09312-w>

WICHOWSKI, P.; KALENIK, M.; LAL, A.; MORAWSKI, D.; CHALECKI, M. Hydraulic and technological investigations of a phenomenon responsible for increase of major head losses in exploited cast-iron water supply pipes. *Water*, v. 13, n. 11, p. 1604, 2021. <https://doi.org/10.3390/w13111604>

ZOUNEMAT-KERMANI, M.; RAMEZANI-CHARMAHINEH, A.; ADAMOWSKI, J.; KISI, O. Investigating the management performance of disinfection analysis of water distribution networks using data mining approaches. *Environmental Monitoring and Assessment*, v. 190, 2018. <https://doi.org/10.1007/s10661-018-6769-1>