

Modelagem de Um Sistema de Abastecimento de Água Baseado em Redes Neurais Artificiais

Jose H. B. da Silva* Rafael M. Duarte ** Thommas K. S. Flores ***
João S. S. Junior **** Juan M. M. Villanueva †

* *Faculdade de Engenharia Elétrica, Universidade Federal da Paraíba, PB, (e-mail: jose.dasilva@cear.ufpb.br).*

** *Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal da Paraíba, PB (e-mail: Rafael.duarte@cear.ufpb.br)*

*** *Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal da Paraíba, PB (e-mail: thommas.flores.101@ufrn.edu.br)*

**** *Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal da Paraíba, PB (e-mail: Joao.junior@cear.ufpb.br)*

† *Departamento de Engenharia Elétrica, Universidade Federal da Paraíba, PB, (e-mail: jmauricio@cear.ufpb.br)*

Abstract: The use of control systems is often associated with efficient and effective models. Currently, many water supply systems, which are essential to society, lack adequate control systems, resulting in losses in the process and energy inefficiency. In control system design, the modeling of the system becomes highly important, as it is nonlinear and complex in water supply systems, requiring the development of black-box models using Artificial Intelligence methodologies. Thus, this study aims to develop a model based on artificial neural networks for a water supply system. To achieve results, a pilot plant from the Laboratory of Energy Efficiency in Hydraulics and Sanitation (LENHS/UFPB) was utilized, equipped with a fully instrumented and automated water distribution system. To develop the model, a methodology consisting of four steps was followed: data acquisition, data processing, neural network modeling, and implementation in the supervisory system. The maximum value obtained for the validation metric, mean absolute percentage error, was 1.532% for pressure and 1.7239% for flow rate. These results solidify the effectiveness of the method and its applicability in water distribution systems.

Resumo: A utilização de sistemas de controle costuma estar associada a modelos eficientes e eficazes. Atualmente, muitos dos sistemas de abastecimento de água, que são essenciais para a sociedade, não possuem um sistema de controle adequado, resultando em perdas de cargas no processo e em ineficiência energética. No projeto de sistemas de controle, torna-se de grande importância a modelagem do sistema, sendo altamente não linear e complexo em sistemas de abastecimento de água, requerendo o desenvolvimento de modelos do tipo caixa-preta utilizando metodologias baseadas em Inteligência Artificial. Dessa forma, este trabalho tem por objetivo desenvolver um modelo baseado em redes neurais artificiais de um sistema de abastecimento de água. Com a finalidade de obter resultados, foi utilizada uma planta piloto do Laboratório de Eficiência Energética em Hidráulica e Saneamento (LENHS/UFPB), que conta com um sistema totalmente instrumentalizado e automatizado de distribuição de água. Para desenvolver o modelo, seguimos uma metodologia composta por quatro etapas: aquisição de dados, tratamento dos dados, modelagem com redes neurais e implementação no sistema supervisão. O valor máximo obtido para a métrica de validação, erro absoluto médio percentual, foi de 1,532% para a pressão e 1,7239% para a vazão. Esses resultados consolidam a eficácia do método e sua aplicabilidade em sistemas de distribuição de água.

Keywords: ANN; modeling; water distribution system, pressure, water flow

Palavras-chaves: RNA; modelagem; sistema de distribuição de água; pressão; vazão.

1. INTRODUÇÃO

Diante do crescimento populacional em centros urbanos, a demanda por água potável tem aumentado demasiadamente, gerando riscos e vulnerabilidades relacionadas à escassez desse recurso (Diniz et al., 2019). Um levantamento divulgado pelo Instituto Trata Brasil (ITB) mostrou que mais de 40% da água captada pelos reservatórios brasileiros é desperdiçada ao longo de todo o processo até chegar ao consumidor. Tais problemas enfatizam a importância de pesquisar e implementar técnicas que tornou o sistema de abastecimento de água mais eficiente, seja melhorias mecânicas ou melhorias elétricas.

De acordo com CAVALCANTI et al. (2019), a eficiência das redes de distribuição de água é influenciada por vários fatores, tais como vazamentos, deterioração da infraestrutura, consumo de energia dos conjuntos motores-bomba e a regulação da pressão e vazão. Além disso, aponta que estes dois parâmetros são eficientemente controlados a partir do controle da velocidade conjunto motor-bomba. Por conseguinte, automatizar o sistema de abastecimento de água representa uma alternativa às perdas presente nesse processo.

Na literatura são encontrados diversos métodos de controle que vão desde métodos que dependem do humano até métodos mais modernos como o uso de controladores PID. No entanto com a popularização dos conceitos de Inteligência Artificial, Machine Learning, Big Datas, os controladores como controle fuzzy e controle adaptativo tem ganhado espaço sobretudo quando o sistema é variável ao longo do tempo.

O desenvolvimento de um controlador, PID por exemplo, requer um modelo matemático fiel à planta para sintonização das constantes. Porém, modelar matematicamente um sistema de abastecimento de água representa uma tarefa complexa, talvez infactível, uma vez que, para cada ponto de operação, as equações que descrevem o sistema se alteram (Barros Filho et al., 2016). Portanto, há a necessidade de modelar a planta a partir de métodos não tradicionais tais como: modelagem baseada em simulações, modelagem baseada em redes neurais artificiais (RNA) e modelagem baseada em identificação de sistemas.

A modelagem baseada em redes neurais é uma abordagem que faz uso de redes neurais artificiais para representar e prever o comportamento de sistemas complexos. Visto que o sistema de abastecimento de água é complexo e o comportamento é não linear, esse tipo de modelagem é vantajoso.

Dessa forma, com a finalidade de analisar a eficiência energética de uma rede de distribuição de água no Laboratório de Eficiência Energética Em Hidráulica e Saneamento (LENHS) na Universidade Federal da Paraíba (UFPB),

* Agradecemos ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e à UFPB pelo suporte financeiro para desenvolver a pesquisa por meio do PIBIC-UFPB-CNPQ-FAPESQ 2022-2023

este trabalho tem como objetivo o desenvolvimento da modelagem de um trecho associado a um sistema de distribuição de água, composto por um conjunto motor-bomba, inversor de frequência, eletroválvula, sensor de pressão e sensor de vazão.

2. SISTEMA DE ABASTECIMENTO DE ÁGUA

Um sistema de abastecimento de água desempenha um papel crucial no fornecimento de água potável para comunidades, bairros e cidades. Esses sistemas operam por meio de uma série de etapas, desde a captação da água bruta até a distribuição aos consumidores finais. Na Figura 1, ilustra-se um sistema de abastecimento de água contemplando todas as etapas.

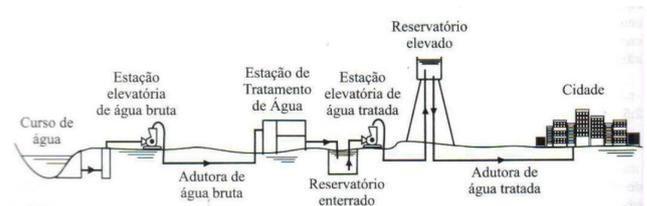


Figura 1. Sistema de abastecimento de água.

A partir da Figura 1, observa-se que o sistema é representado pelas seguintes componentes:

- **Captação:** a água é captada a partir de fontes naturais, como rios, lagos, represas ou aquíferos subterrâneos.
- **Tratamento:** A água bruta passa por um processo de tratamento para remover impurezas, substâncias químicas, microrganismos e outros poluentes.
- **Reservação:** a água tratada é armazenada em reservatórios ou torres de água para garantir o suprimento contínuo e regularidade do abastecimento.
- **Rede de distribuição:** a água é distribuída por uma extensa rede de tubulações que abrange toda a região a ser atendida. .

Para o correto funcionamento de pontos de elevação e redes de distribuição, várias unidades motor-bomba estão presentes. Elas fornecem energia ao líquido para realizar o movimento necessário. O acionamento dessas máquinas é frequentemente feito com um inversor de frequência, que oferece a vantagem de possibilitar o controle de velocidade através de um controlador convencional ou inteligente.

3. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são eficazes para solucionar problemas complexos de aprendizado de máquina. Especificamente, as multicamadas perceptron (MLP) são amplamente empregadas devido à sua habilidade em lidar com problemas não lineares e realizar tarefas precisas de classificação e regressão.

A operação de uma rede neural MLP é fundamentada no princípio do perceptron, conceito desenvolvido por Frank

Rosenblatt. Esse mecanismo opera como um "classificador linear", responsável por categorizar os dados de entrada e emitir uma saída binária correspondente a essa classificação Rosenblatt (1958). A Figura 2 apresenta a ilustração do conceito. A excitação do neurônio deriva da soma ponderada dos sinais de entrada, x_i , representados como $[x_1, x_2, x_n]$, multiplicados pelos pesos neuronais W_i . O valor resultante então passa pela função de ativação, e se exceder o limiar determinado, o neurônio transmitirá o valor. Caso contrário, o neurônio permanecerá inativo (Unpublished).

As funções de ativação têm papel crucial nas redes neurais MLP, introduzindo a não linearidade nas saídas dos neurônios e permitindo à rede modelar relações complexas. Funções como logística e tangente hiperbólica são frequentemente usadas por serem não lineares e de comportamento simples (Kopiler et al., 2019).

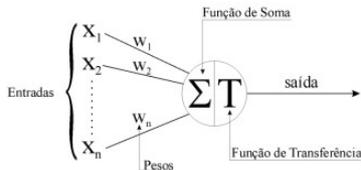


Figura 2. Perceptron.

Uma rede neural MLP é composta por várias camadas de neurônios interconectados. Ela consiste em uma camada de entrada, uma ou mais camadas ocultas e camada de saída, todas compostas por neurônios. Neurônios em uma camada estão conectados a neurônios nas próximas camadas através de pesos sinápticos. A camada de entrada recebe os dados de entrada, as camadas ocultas processam esses dados e a camada de saída produz os resultados desejados. Na Figura 3 é ilustrado o modelo de rede neural artificial.

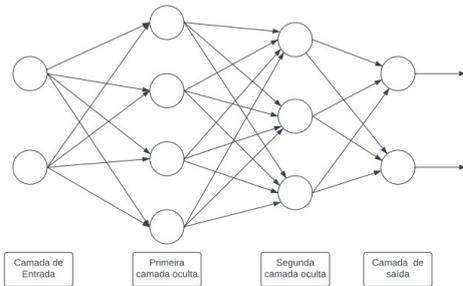


Figura 3. Estrutura de rede de neurônios perceptrons .

Durante o processo de treinamento da rede, os pesos sinápticos passam por ajustes iterativos por meio de algoritmos de aprendizado, como o *Backpropagation*. Kopiler et al. (2019) destaca que esse algoritmo efetua a retropropagação do erro calculado na camada de saída para as camadas anteriores. Essa abordagem possibilita a correção dos erros nos neurônios prévios, promovendo ajustes nos pesos sinápticos de maneira a minimizar o erro global da rede.

4. METODOLOGIA

Nesta seção será apresentada a metodologia para a construção de modelos de sistemas de abastecimento de água baseados em Redes Neurais Artificiais. Na Figura 4,

ilustra-se o diagrama de blocos desta proposta, sendo constituído por 4 módulos: Aquisição de dados, Tratamento e processamento de dados, Modelagem baseado em RNA e Implementação em um sistema Supervisorio. Na sequência, cada módulo será explicado, desenvolvido e aplicado a uma rede de abastecimento de água.

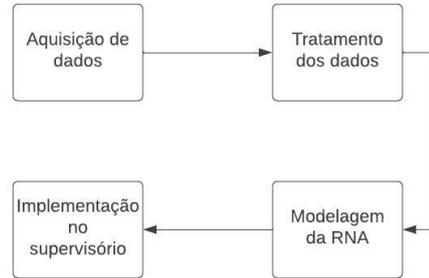


Figura 4. Diagrama de blocos da metodologia aplica para modelagem do sistema de abastecimento

Para este proposito, foi utilizado o Laboratório de Eficiência energética em Hidraulica e saneamento da Universidade Federal da Paraíba LENHS/UFPB, cuja vista panorâmica encontra-se ilustrada na Figura 5.



Figura 5. Vista Panorâmica do laboratório

4.1 Aquisição dos dados

O planta utilizada neste trabalho é o trecho do sistema de abastecimento de água do LENHS-UFPB ilustrado na Figura 6. Este trecho possui um conjunto motor-bomba, um inversor de frequência, um reservatório aterrado, um sensor de vazão eletromagnético, uma eletroválvula e um transdutor de pressão.

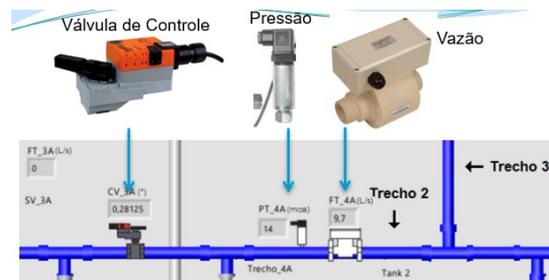


Figura 6. Planta do LENHS

Os pontos de medição usados para modelagem do sistema estão localizados no trecho destacada na Figura 6 e representados pelos seguintes componentes:

- CV_3A: Eletroválvula;
- FT_4A: Transdutor de vazão eletromagnético;
- PT_5A: Transdutor de pressão;

O sistema de aquisição de dados utilizado, que realiza a comunicação entre os sinais elétricos dos sensores e o sistema supervisor, é composto pelo Controlador Lógico Programável (CLP) ATOS 4004, o qual se comunica com o supervisor, desenvolvido no *software Labview*, por meio do protocolo Modbus a uma taxa de até 20 kbit/s.

Para coletar os dados de treinamento da rede neural, o ângulo da válvula foi variado de 0 à 36 graus, com passo de 9 graus e, para cada ângulo da válvula, a frequência foi variada de 30 a 50Hz com passo de 5Hz. Essas variações foram realizadas com o intuito de observar a dinâmica da pressão e da vazão nas tubulações para diferentes cenários de consumo. É importante citar que a amostragem dos dados salvos tem um período de 380 ms e cada cenário com duração de três minutos. Portanto, são aproximadamente 474 linhas de dados por cada cenário.

4.2 Tratamento de dados

Em aquisição de dados é comum a presença de *outliers* resultantes de ruídos na transmissão de dados ou na coleta realizada pelo transdutor. Em alguns conjuntos de amostras, como demonstrado na Figura 7, *outliers* foram facilmente detectados. Já em outros conjuntos, somente se tornam evidentes com as análises mais precisas.

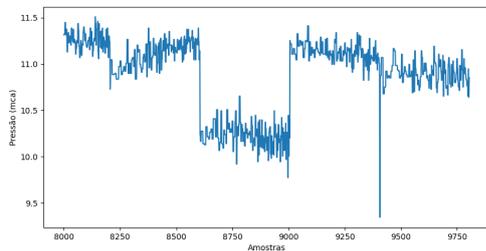


Figura 7. Presença de outliers nos dados

Para a remoção dos *outliers*, foram aplicados dois filtros: um para remover números negativos e outro para remover dados fora do intervalo interquartil, isto é, dos 50 por cento intermediários dos dados, esse intervalo é frequentemente usado para tratamento de *outliers* na literatura. Para aplicar esta medida, a base de dados foi dividida em 18 conjuntos com o objetivo de reduzir o erro do intervalo interquartil. Para o conjunto ilustrado na Figura 7, os dados filtrados estão representados na Figura 8.

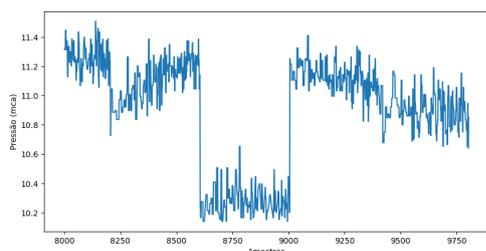


Figura 8. Frequências

Após o tratamento, a base de dados para treinar a rede neural artificial passou a ser composta por 7896 linhas de informações. Para base de teste, restaram 3409 linhas.

4.3 Modelo da RNA

Foram utilizadas como variáveis de entrada da RNA a frequência do motor, o ângulo da eletroválvula, a pressão e a vazão na tubulação. A seleção das variáveis foi fundamentada em uma análise cuidadosa das características e requisitos da planta. Sua escolha se deu devido à influência direta e significativa que exercem sobre o desempenho do sistema. A frequência do motor é um fator crítico, uma vez que determina a velocidade de bombeamento, afetando diretamente a vazão de água na tubulação. O ângulo da eletroválvula desempenha um papel crucial no controle do fluxo de água, permitindo ajustes precisos na quantidade de água fornecida. A pressão na tubulação é um indicador essencial da estabilidade e eficiência do sistema, enquanto a vazão na tubulação reflete diretamente a quantidade de água entregue aos consumidores.

Dessa forma, foi feito um tratamento para adequar os dados ao modelo da RNA. Tal como é observado na Figura 9, o modelo possui dez vetores, entre os quais são de entrada: frequência atual, ângulo da válvula atual (CV_READ_4A), pressão com três atrasos de amostras (PT_4A(t-1), PT_4A(t-2), PT_4A(t-3)) e vazão com três atrasos de amostras (FT_4A(t-1), FT_4A(t-2), FT_4A(t-3)), já a saída, ou o padrão que a rede deve aprender, são a pressão no tempo e vazão atual (PT_4A(t), FT_4A(t)) respectivamente.

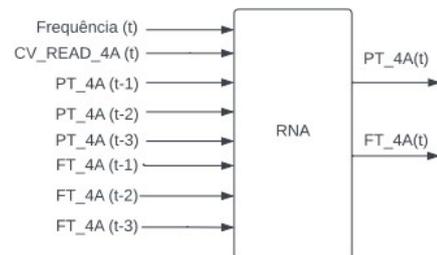


Figura 9. Modelo da rede neural artificial

Para implementar a rede neural artificial foi utilizado o *software Matlab*. Os parâmetros utilizados na topologia estão descritos na Tabela 1, estes foram adquiridos por meio da tentativa e erro de forma a diminuir o erro da resposta da rede.

Tabela 1. Parâmetros da rede implementada.

Função de ativação	logsig
Função de treinamento	trainlm
Número de camadas	2
Números de neurônios por camada	10
Número máximo de épocas	50
Erro mínimo desejado	0,001

Nas Figuras 10 e 11, é possível observar a validação do treinamento da rede neural. Na representação gráfica, a variável prevista está destacada em azul, enquanto a medida

real está representada em vermelho. Para avaliar o desempenho do modelo, foi adotada a métrica de erro absoluto médio percentual (MAPE), escolhida por sua expressão em termos percentuais e facilidade de compreensão. Essa escolha permite entender claramente a magnitude do erro em relação ao valor real.

Na análise da pressão (Figura 10), o cálculo do erro absoluto médio percentual (MAPE) resultou em 0,64%, enquanto para a vazão (Figura 11), o MAPE calculado foi de 0,2%. Esses valores representam a precisão relativa do modelo em relação às medidas reais, consolidando sua eficácia na previsão.

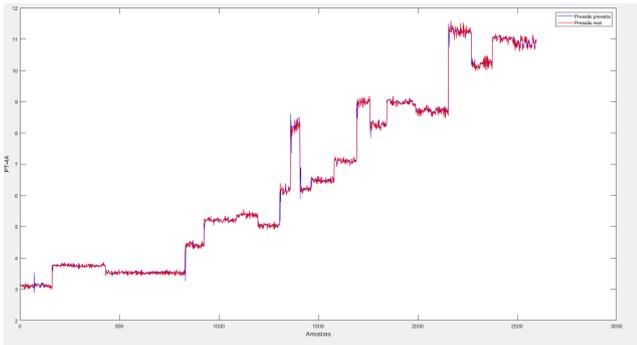


Figura 10. pressão prevista e pressão real

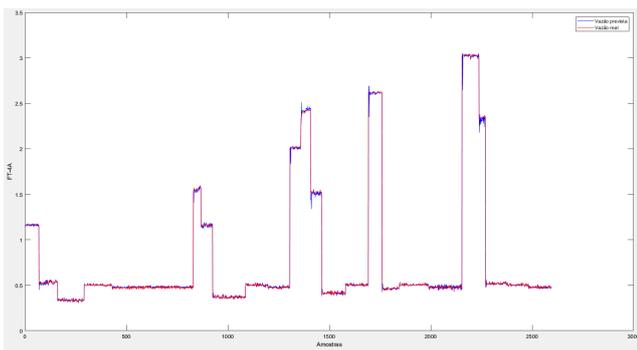


Figura 11. Vazão prevista e vazão real

4.4 Implementação

Após a validação, a rede neural foi implementada no supervisório, neste caso desenvolvido no Labview, para acompanhamento em tempo real das variáveis modeladas. A plataforma Labview possui um bloco capaz de executar e carregar arquivos do Matlab, o que facilita a implementação da rede.

5. ANÁLISE DOS RESULTADOS

Nesta seção serão apresentados e discutidos os resultados do modelo implementado no software supervisório. Inicialmente foi observado o comportamento do modelo em relação aos dados reais e, posteriormente, esses dados foram coletados e analisados estatisticamente.

5.1 Visualização no supervisório

Na Figura 12 é apresentado um seção do supervisório implementado destacando-se a pressão prevista pelo modelo,

a medida pelo sensor PT_4A, destacado na Figura 6, e a frequência de operação do inversor. O gráfico traçado pelo programa exibe a curva dos pontos previsto em vermelho e a curva dos pontos medidos em branco.



Figura 12. Pressão prevista e pressão real no labview

Na Figura 12, é evidente que as curvas estão praticamente sobrepostas. Em um ponto específico da curva, a pressão prevista registrou 6,99487 mca, enquanto a pressão real medida foi 7,13588 mca. Isso resulta em um erro absoluto de apenas 0,14 mca, indicando a eficácia do modelo.

5.2 Análise dos dados coletados

O modelo foi submetido a testes para frequências de 30Hz a 50Hz com passo de 5Hz, foi cronometrado 90 segundos para cada frequência. Os resultados estão exibidos nas Figuras 13 e 14.

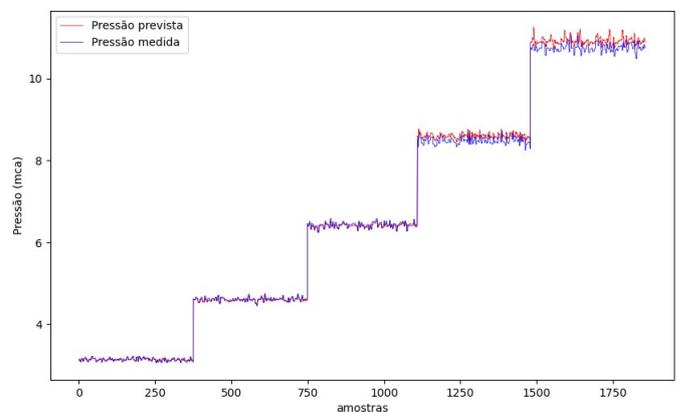


Figura 13. Pressão

Analisando visualmente o gráfico da Figura 13, observa-se que o modelo é muito aproximado da planta entre as amostras 0 e 1100 aproximadamente que corresponde às frequências de 30Hz, 35Hz e 45Hz. Já nos dois últimos degraus, entre as amostras 1100 e 1800, o erro se torna mais visível.

Na tabela 2 é demonstrado a análise de erro entre as pressões para as diferentes frequências.

Analisando a tabela 2, é visto que quanto maior for a frequência maior será o MAPE. Isso ocorre pelo aumento de perturbações no sistema. No entanto, é visto que o maior MAPE é de 1,532%, que representa uma diferença

desprezível entre o modelo e o medido para este processo. Além disso, vê-se que para frequência entre 30 Hz e 40Hz o MAPE é menor que 1%. Portanto, está demonstrada a eficiência do modelo.

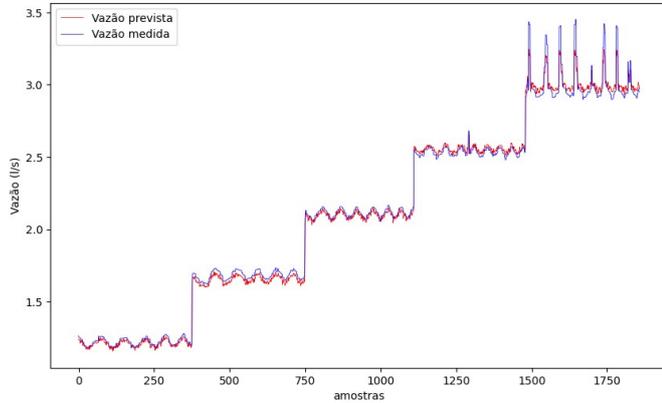


Figura 14. Vazão

Na Figura 14 é apresentada a saída da vazão modelada e amedida pelo sensor. Observa-se que as maiores perturbações ocorre para a frequência em 50Hz e, além disso, é visto que o modelo se adequou bem à planta. Os dados de erro que corroboram essas observações estão dispostos na tabela 3.

Ao analisar a tabela 3, fica evidente que a vazão estimada apresentou maior proximidade com a vazão real nas frequências de 40Hz e 45Hz, o que é respaldado pelo MAPE inferior a 1%, e a maior diferença ocorreu em 35Hz se aproximando de 1.7%. No entanto, analisando o erro absoluto máximo ($E_{máx}$) para 35Hz, que equivale a 0,05474 l/s, conclui-se que é um erro aceitável para esta planta.

Além dos dados apresentado acima, o ângulo da válvula foi variado em diversos valores e as previsões continuaram com as curvas praticamente sobrepostas. Além disso, foi aplicada uma perturbação na planta por meio da abertura de uma das saídas que estava fechada durante a aquisição dos dados. Diante disso, a resposta do modelo também continuou intacta demonstrando resistência à perturbações.

Tabela 2. Análise de erro entre pressão prevista e medida.

Frequência (Hz)	$E_{máx}$ (Hz)	E_{min} (Hz). 10^{-5}	MAPE (%)
30	0.05786	1.20000	0.50300
35	0.06997	7.99990	0.36400
40	0.09431	19.59900	0.46800
45	0.24205	361.39990	1.30400
50	0.49203	154.70000	1.53200

Tabela 3. Análise de erro entre vazão prevista e medida.

Frequência (Hz)	$E_{máx}$ (l/s)	E_{min} (l/s). 10^{-4}	MAPE (%)
30	0.03354	1.95000	1.08499
35	0.05474	2.40990	1.7239
40	0.03872	1.82990	0.78601
45	0.05314	2.21900	0.81220
50	0.25284	4.05990	1.655

6. CONCLUSÃO

Neste estudo, foi elaborado um modelo baseado em redes neurais artificiais, direcionado para um sistema de abastecimento de água, com foco em duas variáveis críticas: vazão e pressão. O desenvolvimento do modelo seguiu a metodologia previamente descrita, abrangendo desde a coleta de dados para treinamento até a sua integração no sistema supervisorio.

A confirmação da validade do modelo surge através dos resultados altamente satisfatórios tanto para a pressão, com um MAPE máximo de 1,532%, quanto para a vazão, com um MAPE máximo de 1,7239%. Esta conquista ressalta a extrema proximidade do modelo em relação à planta real, evidenciando sua aplicabilidade eficaz ao sistema.

Este trabalho introduz uma metodologia aplicável em variados contextos e, por não ser de grande complexidade, torna-se uma ferramenta interessante para a identificação de plantas que não podem ser facilmente modeladas matematicamente. Além disso, com base nesse modelo, trabalhos futuros podem evoluir ao desenvolvimento e validação de um controlador baseado em lógica fuzzy, apropriado para sistemas não lineares.

Em conclusão, este trabalho alcançou com sucesso seu principal objetivo de modelar e validar o segmento do sistema de distribuição de água do LENHS, que foi submetido a testes.

AGRADECIMENTOS

Os autores são gratos ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e a UFPB pelo suporte financeiro para desenvolver a pesquisa por meio do PIBIC-UFPB-CNPQ-FAPESQ 2022-2023. São gratos ao Laboratório de Eficiência Energética e Hidráulica em Saneamento da Universidade Federal da Paraíba (LENHS/UFPB) pela estrutura fornecida para a realização de experimentos.

REFERÊNCIAS

- Barros Filho, E.G.d. et al. (2016). Sistema inteligente para o controle de pressão de redes de distribuição de água abastecidas por bombas associadas em paralelo.
- CAVALCANTI, D.B., MOURA, J.J.P., VILLANUEVA, J.M.M., and GOMES, H.P. (2019). Modelagem de um sistema de bombeamento para o controle de vazão por conversor de frequência baseado na teoria de identificação de sistemas. In *Congresso Brasileiro de Automática-CBA*, volume 1.
- Diniz, T.G. et al. (2019). Vulnerabilidade ao desabastecimento em situação de intermitência no abastecimento de água.
- Kopiler, A.A., Silva, V., Oliveira, L.A.A.d., Linden, R., Silva, L., and Fonseca, B.L.d.C. (2019). Redes neurais artificiais e suas aplicações no setor elétrico. *Revista de Engenharias da Faculdade Salesiana*, 1(9), 27-33.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.