

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

### **DESENVOLVIMENTO DE METODOLOGIA PARA A PREVISÃO DE PERDAS COM O PROTÓTIPO DE GÊMEO PRÉ-DIGITAL E REDE NEURAL ARTIFICIAL RECORRENTE LONG SHORT TERM MEMORY**

*Sara Maria Marques<sup>1</sup>; Fernando das Graças Braga da Silva<sup>2</sup>, Lorena Lemos Dias Lara<sup>3</sup>, Alex Takeo Yasumura Lima Silva<sup>4</sup> & Solange Cristina Raimundo Alves<sup>5</sup>*

**Abstract:** Water distribution networks are complex systems that suffer from high losses due to inefficient management and control of their operation, which compromise adequate service to the population. Therefore, studies and techniques are developed to improve efficiency, making systems more intelligent. Thus, a methodology is proposed for predicting losses in a benchmark network with the joint application of the pre-digital twin prototype and the LSTM recurrent artificial neural network, aiming to find the worst losses for a 24-hour period of operation based on historical data from 48 hours of network operation, to achieve efficient system management. The result showed that the methodology was effective, since the simultaneous exchange of network data carried out by the digital twin occurred instantly and without errors. In addition, the RNAR-LSTM used for the prediction presented an accuracy of 97.5%, thus proving the capacity of the developed methodology.

**Resumo:** As redes de distribuição de água são um sistema complexo que sofrem com perdas elevadas devido a ineficiência da gestão e no controle de seu funcionamento, que comprometem o atendimento adequado à população. Com isso, o desenvolvimento de estudos e técnicas que permitam a melhorar a eficiência, tornando os sistemas mais inteligentes. Assim, é proposto uma metodologia para a previsão de perdas de uma rede de benchmark com a aplicação conjunta do protótipo de gêmeo pré-digital e de rede neural artificial recorrente LSTM, visando encontrar as piores perdas para um período de 24 horas de operação com base em dados históricos de 48 horas de funcionamento da rede, para alcançar uma gestão eficiente do sistema. O resultado encontrado mostrou que a metodologia foi eficaz, pois a troca simultânea de dados da rede realizada pelo gêmeo digital ocorreu de forma instantânea e sem erros, além disso a RNAR-LSTM utilizada para a previsão apresentou uma precisão de 97,5%, comprovando assim a capacidade da metodologia desenvolvida.

**Palavras-Chave** – Previsão de perdas, Gêmeo Digital, Rede Neural Artificial Recorrente

### **INTRODUÇÃO**

A água é um recurso natural importante para o desenvolvimento da humanidade e suas atividades. Devido a isso, é importante o desenvolvimento de estudos e tecnologias que permitam uma gestão mais eficiente desse recurso, principalmente em sistemas de abastecimento que sofrem

1) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: saramarques.eng.civil@gmail.com

2) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: fernandobraga@unifei.edu.br

3) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: lorenaldlara@unifei.edu.br

4) ICPA: Instituto de Ciências Puras e Aplicadas, Universidade Federal de Itajubá, Campus Itabira, Itabira-MG, Email:alex.takeo@unifei.edu.br

5) Princ. Estrat. Discente de Energia egressa. Email: solange\_cristina\_alves@hotmail.com

com grandes perdas de água. De acordo com o Sistema Nacional de Informações sobre Saneamento (SINISA), o total de perdas das empresas nacionais de saneamento do Brasil foi de 37,8% em 2023, que comparado com países como EUA e Austrália, que possuem valores de perdas de 13% e 17%, respectivamente, é um valor elevado (Brasil, 2021; Brasil, 2023).

Assim, se destacam estudos, que se utilizam de ferramentas como os Gêmeos Digitais (GD) e as Rede Neurais Artificiais, para o maior conhecimento desses sistemas. Os GD podem ser definidos como uma representação de um sistema real em um ambiente virtual dinâmico e progressivo, onde ocorre troca de informações em tempo real ou não entre os ambientes físicos e virtuais (Singh *et al.*, 2021). Dessa forma, são constituídos basicamente por um objeto físico, virtual e a conexão entre ambos os objetos (Syed *et al.*, 2024).

A utilização dos gêmeos digitais pode variar de acordo com o seu uso e aplicação, podendo ser do tipo protótipo, caracterizando pela criação do modelo virtual antes do modelo real, para que testes e identificação de cenários mais adversos que são difíceis de serem identificados possam ser realizados sem prejuízo ao sistema. Ou instância, que se define pelo desenvolvimento do modelo virtual depois do modelo real (Grieves; Vickers, 2017; Singh, 2021). Além disso, também podem ser caracterizados em pré-digital, gêmeo digital e gêmeo digital adaptativo. O pré-digital caracteriza-se pela existência do modelo virtual antes do físico para que riscos e problemas técnicos possam ser evitados no sistema real. O gêmeo digital ocorre pela troca de informações entre o físico e o virtual de maneira simultânea e o gêmeo digital adaptativo possui a mesma característica do gêmeo digital, porém há a utilização de aprendizado de máquina para aprimorar as preferências e prioridades do sistema (Madni *et al.*, 2019).

Dessa forma, o uso da prototipagem tem o menor custo de utilização, porque possibilita a realização de testes destrutivos, sem comprometer o sistema real (Grieves; Vickers, 2017). Sua utilização em redes de distribuição de água permite o monitoramento dos componentes da rede, além de possibilitar a análise de comportamentos operacionais das redes, identificando perdas de água, a variação de demanda e de pressão, sendo também aplicados na manutenção preditiva e na otimização da operação das redes (Dui; Cao; Wang, 2025).

Observa-se na literatura estudos que se utilizam dessa tecnologia para os estudos de redes, como mostra Pompeu e Nepomuceno (2023) desenvolveu uma metodologia para a tomada de decisão para a otimização e previsão de demanda de uma rede de distribuição de água, utilizando da aplicação conjunta do GD e modelo linear. Foram elaborados vários cenários de simulação até que fosse encontrado um em que os valores fossem otimizados. O resultado foi uma economia energética de 19,5%, verificando a eficiência da metodologia apresentada.

Em Ramos *et al.* (2022), trouxeram uma aplicação de GD para a detecção de perdas em um sistema da cidade de Lisboa-Portugal. O modelo desenvolvido considera parâmetros como a evolução da rede ao longo do dia, a variação do consumo, os horários de picos de consumo, a vazão e pressão ao longo do dia para a determinação das perdas. A simulação com a utilização do GD foi eficiente, pois foi capaz de encontrar a perda do sistema e reduzi-la, sendo uma redução de 15% do volume perdido.

Já a Rede Neurais Artificiais Recorrentes (RNA) é uma técnica de aprendizado de máquina, desenvolvida com base no funcionamento do cérebro humano, em que há relação entre o conjunto de sinais de entrada e saída, assim como o funcionamento dos neurônios.

Na literatura encontra-se em Rolle *et al.* (2022) o desenvolvimento de um estudo para o monitoramento de rede de água de benchmark para detecção de vazamentos de água. Para isso, foi aplicado Redes Neurais de Grafo levando em consideração variáveis como a pressão e a localização



dos nós. Os resultados encontrados se mostraram promissores para a detecção de perdas físicas em redes de distribuição com o uso de RN de Grafos, porém, segundo os autores os resultados ainda são preliminares, necessitando de mais tempo de simulação para os resultados definitivos dessa aplicação.

Silqueira et al. (2024), apresentou um modelo com aplicação conjunto do ARIMA e Redes Neurais Artificiais do tipo Perceptron, para a previsão de pressão e vazão em um sistema de distribuição de água real do sudeste do estado de Minas Gerais, Brasil. O objetivo foi reduzir as perdas mantendo o atendimento das demandas do sistema. O resultado mostrou que o modelo ARIMA possui maior capacidade de previsão que as RNA do tipo Perceptron, além disso, são mais fáceis de serem aplicadas para o tipo de estudo que foi desenvolvido.

Assim, o presente estudo desenvolveu uma metodologia aplicando das duas técnicas apresentadas, protótipo de gêmeos pré-digitais e a Rede Neural Artificial recorrente LSTM, com o objetivo de prever as perdas físicas de uma rede de benchmark da literatura, Anytown, para uma gestão mais eficiente do sistema, através do conhecimento de cenários de piores perdas prevista para as 24 horas de operação.

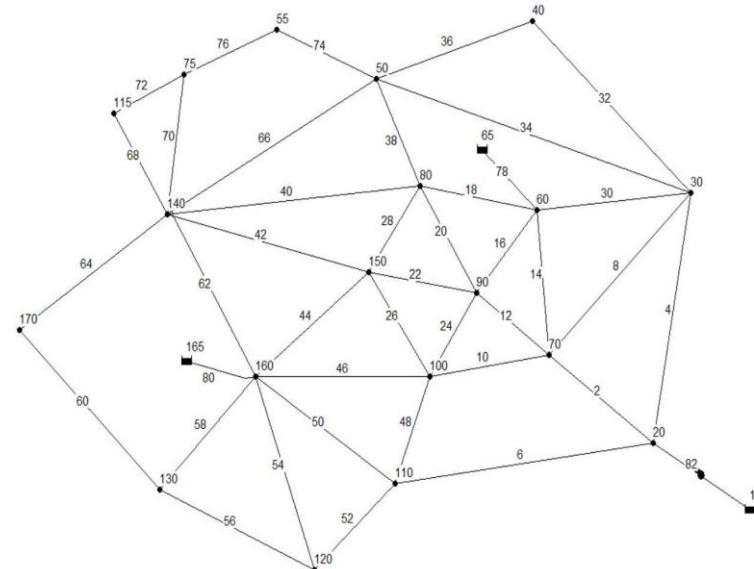
## MATERIAIS E MÉTODOS

A metodologia desenvolvida para a presente pesquisa foi estruturada em etapas: 1 - Definição da rede de estudo; 2 - Elaboração do protótipo de gêmeo pré-digital; 3 - Elaboração do modelo de previsão de perdas com rede neural artificial LSTM; 4 - Aplicação conjunta das duas ferramentas

## **Etapa 1 - Definição da rede de estudo**

O sistema de distribuição utilizado para a aplicação da metodologia desenvolvida foi a rede de benchmark Anytown que foi desenvolvida por Walski et al. (1987). Esse sistema é formado por 19 nós, 42 tubulações, 3 reservatórios e 1 bomba, e possui o layout de malha. Para o estudo foi definido para o material das tubulações o PVC que apresenta uma rugosidade média de 0,06 mm de acordo com Porto (2006). Além disso, o diâmetro varia entre 200 a 300 mm e o comprimento total das tubulações presente na rede é de 35,4 km. Seu layout está apresentado na Figura 1, bem como as identificações e a localização de cada elemento que compõem essa rede.

Figura 1 - Rede de benchmark usada no estudo



Essa rede foi selecionada para o estudo para que a validação da metodologia desenvolvida fosse viável, pois a rede Anytown possui uma proporção pequena o que permite a identificação maior e

mais rápida de possíveis problemas no desenvolvimento dos algoritmos e assim a sua resolução. E com isso, poder replicar com maior segurança a metodologia apresentada em sistemas mais complexos e robustos.

Assim, a rede passou inicialmente por uma simulação hidráulica estática no EPANET para analisar seu comportamento, verificando a direção do fluxo, as pressões, as vazões, dentre outros, verificando sua viabilidade para o estudo. Na sequência foi realizado uma simulação hidráulica dinâmica da rede para um período de 48 horas de funcionamento, para que fosse possível a elaboração e aplicação do gêmeo pré-digital usando esse período de operação para a previsão dos piores cenários de perdas para esse sistema.

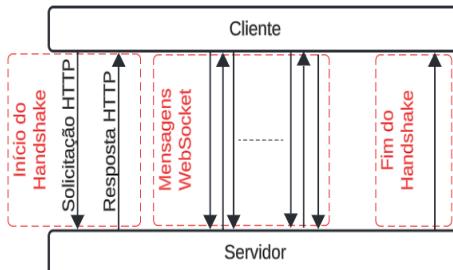
Para a elaboração dos algoritmos foi utilizado a linguagem de programação Python, por apresentar inúmeras bibliotecas e por ser de código aberto, o que possibilita a sua utilização para o estudo. Assim, para a obtenção dos dados da rede foi aplicada a biblioteca EPANET-Python Toolkit (Epyt) que permite chamar o EPANET para dentro do Python (Kyriakou *et al.*, 2023). A utilização dessas bibliotecas permite a otimização do tempo do desenvolvimento do estudo, pois não há a necessidade de desenvolver um algoritmo próprio, somente a adaptação da biblioteca para a necessidade da pesquisa. Também traz uma maior confiabilidade pois a ferramenta já foi testada e utilizada em outros tipos de pesquisas de redes, o que confere flexibilidade de sua utilização.

## Etapa 2 - Elaboração do protótipo de gêmeo pré-digital

Para o desenvolvimento do protótipo de gêmeo pré-digital foi utilizado a biblioteca WebSocket, que permite a interação entre o servidor, que é responsável por disponibilizar os dados e o cliente responsável por controlá-los (Augustin, 2013). O WebSocket é um protocolo de comunicação em tempo real, que utiliza o HTTP (Hyper Text Transfer Protocol) para o transporte de dados. E possui uma infraestrutura que é formada pelo proxy, responsável pela conexão servidor/cliente, e a filtragem responsável pelo controle da transferência das informações e a autenticação que realiza a verificação da identidade do servidor antes de iniciar a comunicação (Fette; Melnikov, 2011).

Seu funcionamento ocorre basicamente por meio de duas etapas: o handshake e a transferência de dados. O handshake é iniciado quando o cliente comunica ao servidor a conexão através do HTTP e se não houver erro o servidor retorna ao cliente a mensagem de conexão iniciada. Uma vez iniciada a comunicação ambos os ativos podem transferir informações de forma simultânea, através de uma única comunicação iniciada, sendo o diferencial deste protocolo quando comparado a outros (Fette; Melnikov, 2011; Júnior; Albuquerque, 2017). Esse funcionamento está exemplificado de forma básica na Figura 2 (Bayılmış *et al.*, 2022).

Figura 2 - Funcionamento básico da relação servidor/cliente, através do WebSocket



Toda a comunicação ocorre por meio de comandos, como o “onopen” que inicia a comunicação servidor/cliente e o “onclose” que finaliza a comunicação. Para a transferência de mensagens entre o servidor e o cliente é feita pelo “onmessage” e a troca de informações do cliente/servidor é realizada pelo “send”. Para a verificação de erro entre as iterações é preciso utilizar na estrutura do código o

comando “onerror”. Contudo, os dados transferidos entre os ativos precisam estar no mesmo padrão (Júnior; Albuquerque, 2017; Bayılmış *et al.*, 2022).

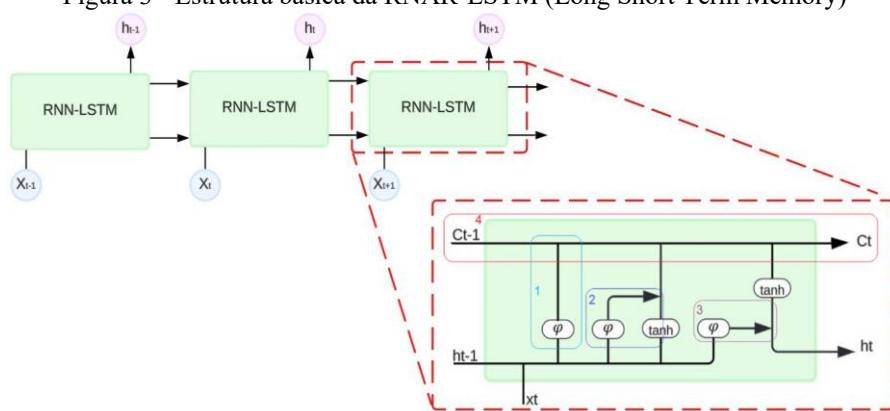
### Etapa 3 - Elaboração do modelo de previsão de perdas com rede neural artificial LSTM

As redes neurais artificiais recorrentes se destacam em relação às demais por possuírem um tempo de treinamento e a sua complexidade de implementação menores. Além disso, se caracterizam por realizarem a realimentação do modelo além da conexão entre os neurônios, como funciona para as demais redes neurais. Diferenciam-se também por necessitarem de um menor número de iterações e parâmetros para o seu treinamento (Unadkat; Ciocoiu; Medsker, 2001; Toscano e Cabral, 2006).

Seu funcionamento ocorre pela conexão reversa, onde os nós se conectam com os nós de camadas anteriores e consigo mesmo, formando o ciclo direcionado. Esse tipo de interação possibilita que a rede neural crie capacidade de memorização, pois o neurônio de entrada possui os valores de neurônios passado junto com a entrada da camada anterior. Com isso, a saída do neurônio atual sofre influência dos valores de saída e de entradas anteriores (Aurélien, 2019). Isso, permite a sua utilização em estudos que precisam de reconhecimento de padrões, onde o resultado anterior pode influenciar os resultados atuais, como é o caso de séries temporais (Hochreiter e Schmidhuber, 1997).

A estrutura da rede neural recorrente utilizada no estudo, a Long Short Term Memory (LSTM), consiste em apresentar duas memórias, uma de curto prazo e um de longo prazo presentes nos portões internos de cada célula, que são formados pelas funções sigmóides que tem a funcionalidade de controlar o quanto de dados devem ser mantidos em cada um dos módulos (Aurélien, 2019). Figura 3, traz a estrutura geral e a ampliação de uma única célula. Onde o número 1 corresponde ao local onde é definido o quanto da memória longa ( $C_{t-1}$ ) será mantido ou descartado. Na região 2 é definido o quanto da memória curta ( $h_{t-1}$ ) e da entrada será incorporado ao estado atual da célula. Em 3 é realizado a combinação do estado atual do módulo com a entrada para formar a saída ( $h_t$ ), porém sem mudar o estado atual ( $c_t$ ) e isso é levado para a próxima célula em paralelo a saída ( $h_t$ ). E por fim a região 4, onde é definido o estado atual da célula e a entrada ( $C_{t-1}$ ) que corresponde a memória longa (Hochreiter and Schmidhuber 1997; Aurélien, 2019; Teixeira *et al.*, 2020; Correia *et al.*, 2021).

Figura 3 - Estrutura básica da RNAR-LSTM (Long Short Term Memory)



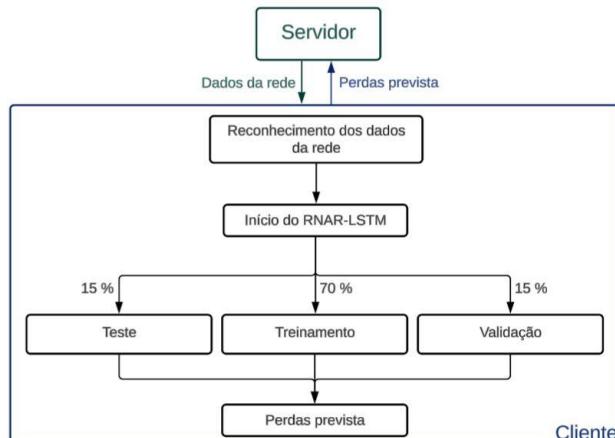
### Etapa 4 - Aplicação conjunta das duas ferramentas

De acordo com as duas ferramentas apresentadas anteriormente foi então realizada sua aplicação conjunta, para a elaboração do algoritmo para a previsão de perdas da rede escolhida para o estudo.

Assim, o algoritmo inicia com a comunicação entre o servidor e o cliente, em que o servidor tem os dados da rede que serão utilizados para a previsão de perdas. A transferência dos dados do

servidor para o cliente foi realizada pelo WebSocket. Esses dados transferidos foram de operação, como perdas e pressões de um período de 48 horas de funcionamento da rede. Uma vez que a comunicação é iniciada e os dados do servidor foram passados para o cliente, foi então iniciada a previsão de piores perdas para as próximas 24 horas de funcionamento da rede, utilizando a rede neural recorrente LSTM, aplicando para isso a biblioteca *Scikit-learn*. Na simulação do algoritmo de previsão foi definido a quantidade de dados que seria utilizada para o treinamento, teste e validação do modelo. Assim, foi definido 70% para o treinamento e 30% para o teste e validação conforme Philip *et al.*, (2024). Com a finalização da simulação do algoritmo, o cliente irá enviar para o servidor os dados encontrados na previsão de perdas, para que o servidor conheça os cenários que podem ocorrer de piores perdas nas próximas 24 horas de funcionamento do sistema e com isso ser possível uma gestão mais eficiente da rede evitando que essas perdas ocorram. A Figura 4 mostra o funcionamento da metodologia desenvolvida.

Figura 4 - Fluxograma do funcionamento da metodologia



A perda utilizada pelo algoritmo na previsão de perdas está expressa na Equação 1 elaborada por Silva (2003). Essa Equação é uma adaptação do estudo apresentado por Germanopoulos e Jowitt (1989) no qual a perda é correlacionada às pressões, considerando-se pequenos vazamentos em torno de cada nó e a pressão da água nos mesmos. Seu valor é dado em porcentagem e a pressão média é determinada pela média aritmética das pressões de cada um dos nós da rede. As constantes presentes na equação foram ajustadas por Silva (2003) com base na faixa média das perdas de redes de distribuição de água. Esta equação de perdas também foi utilizada nos trabalhos desenvolvidos por Silva et al. (2020), Marques et al. (2023), Lara et al. (2024) e Barbedo et al. (2025).

$$\sum_{i=1}^{nodes} losses = P_{mean}^{0,5} * 7,27 \quad (1)$$

O desempenho do modelo de previsão será avaliado por meio de métricas como o Erro Quadrático Médio (MSE), a Raiz do Erro Quadrático Médio (RMSE), o Erro Médio Absoluto (MAE) e o Coeficiente de Determinação ( $R^2$ ). Essas métricas estão exemplificadas pelas Equações 2 a 5 (Zanfei *et al.*, 2022; Zhoa *et al.*, 2019; Bonilla *et al.*, 2025).

$$MSE = \frac{1}{Z} \sum_{i=1}^Z (y_i - \hat{y}_i)^2 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{Z} \sum_{i=1}^Z (y_i - \hat{y}_i)^2} \quad (3)$$

$$MAE = \frac{1}{Z} \sum_{i=1}^Z |y_i - \hat{y}_i| \quad (4)$$

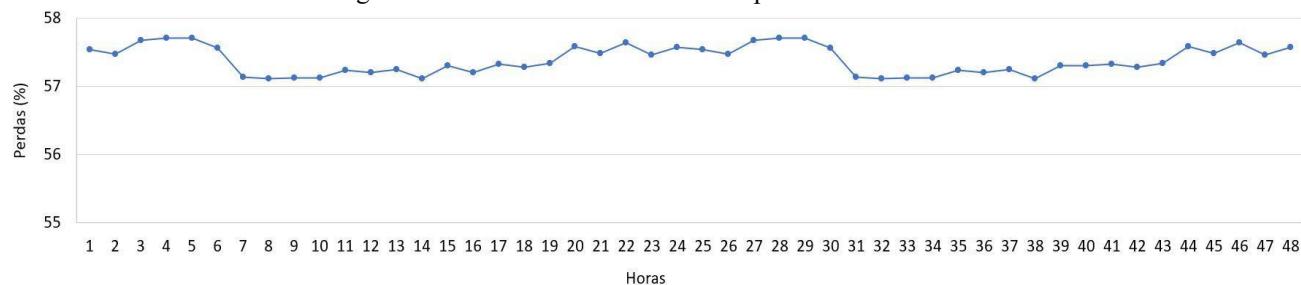
$$R^2 = 1 - \frac{\sum_{i=1}^Z (y_i - \hat{y}_i)^2}{\sum_{i=1}^Z (y_i - \bar{y})^2} \quad (5)$$

Nestas Equações o  $Z$  representa o número de valores previstos e o  $y_i$  corresponde aos valores observados e  $\hat{y}_i$  são as médias dos valores previstos, no intervalo de tempo de uma hora. As métricas MSE, RMSE e MAE para determinar um bom desempenho do modelo precisam apresentar valores baixos. Porém, para o  $R^2$  quanto mais próximo de 1 melhor é o desempenho do modelo (Zanfei *et al.*, 2022; Zhoa *et al.*, 2019; Bonilla *et al.*, 2025).

## RESULTADOS

Para a alimentação do modelo de previsão de perdas desenvolvido pela presente pesquisa, foi elaborada uma simulação dinâmica da rede, definido um período de 48 horas. Essa operação apresentou valores de perdas elevadas, estando acima de 50% para todas as horas. Isso ocorre devido aos valores de pressão apresentados nas simulações da rede, que estão acima do limite estabelecido pela norma NBR 12218. A Figura 5, traz os dados de perdas para cada uma das 48 horas de simulação.

Figura 5 – Perdas da rede de estudo no período de 48 horas

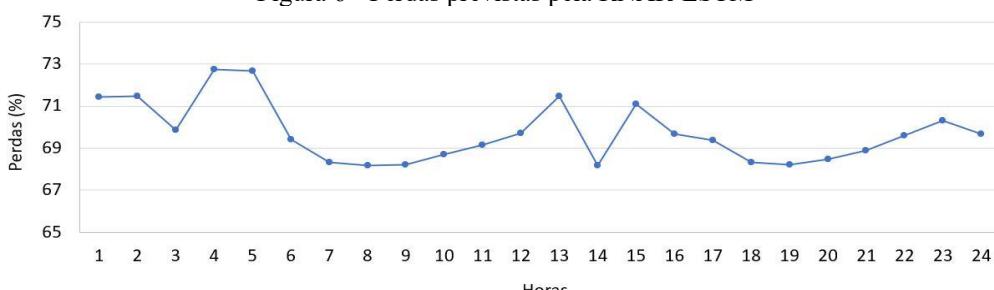


Analisando os dados da Figura 5, observa-se uma pequena variação das perdas para as horas simuladas, que pode ser justificada pela pequena variação de demanda estabelecida para cada uma das 48 horas de simulação. Isso foi definido para que fosse possível o controle da rede caso algum erro de simulação viesse a ocorrer durante a operação do algoritmo. Com isso, foi possível um controle maior da metodologia desenvolvida.

O tempo de comunicação dos dados da rede entre o servidor e cliente ocorreu de maneira instantânea, assim que o pedido foi realizado pelo cliente. Assim, com os dados de pressão e perdas recebidos, o algoritmo de previsão utilizando a rede neural LSTM foi iniciado.

Assim, foram encontradas as perdas previstas para as próximas 24 horas de operação, que estão presentes na Figura 6.

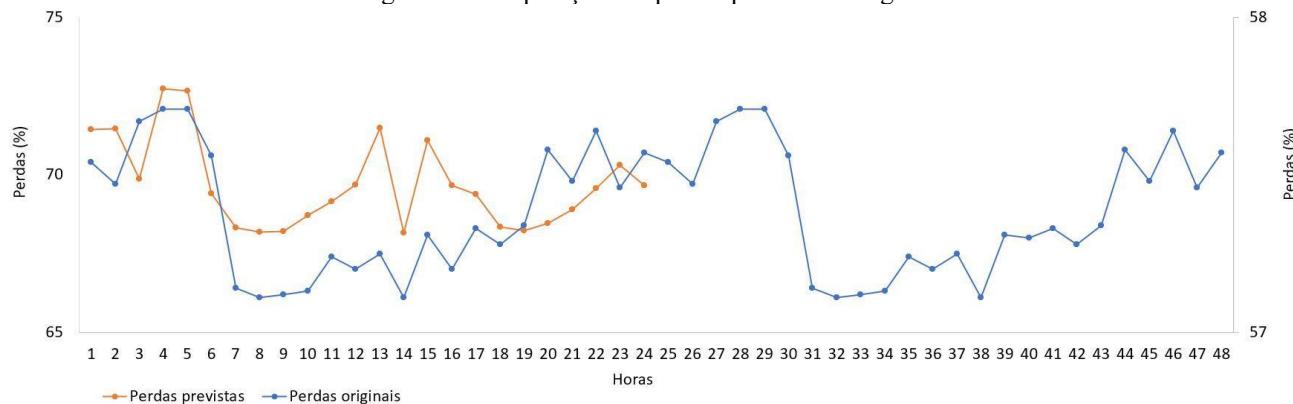
Figura 6 - Perdas previstas pela RNAR-LSTM



De acordo com a Figura 6, observa-se que os valores previstos de perdas apresentam algumas variações extremas, com picos elevados entre as horas 4 e 5. E os menores picos de perdas previstas foram encontrados nas horas 8, 14 e 19, sendo que a hora 14 apresenta o menor valor. Para as demais horas apresentou uma pequena variação dos valores. Contudo, ele conseguiu prever as piores perdas que podem ocorrer no sistema para as próximas 24 horas de operação. Além disso, o comportamento

dos valores previstos, quando comparados com os valores fornecidos para seu treinamento (perdas originais), pode ser considerado semelhantes apresentando os picos para as mesmas horas de maiores perdas e menores, porém há uma diferença a partir da hora 21 pois a perda prevista manteve uma constância crescente enquanto a perda original apresentou uma variação nos valores. A Figura 7 traz a comparação das perdas.

Figura 7 - Comparação das perdas previstas e originais



A avaliação de desempenho do modelo LSTM na previsão de perdas em redes de distribuição, através das métricas já descritas, apresentou resultados para o MSE de 0,0016 e um RMSE de 0,0392, o que indica erros de previsão baixos. O MAE foi de 0,0285, representando um erro absoluto de apenas 2,85%, o que é altamente satisfatório considerando o intervalo dos dados. Além disso, o modelo apresentou um  $R^2$  de 0,9750, evidenciando uma excelente capacidade de explicação da variância dos dados reais pelas previsões do modelo. Em outras palavras, aproximadamente 97,5% da variabilidade nas perdas observadas pode ser explicada pelo modelo preditivo. Os resultados mostraram uma consistência significativa entre os subconjuntos de teste, com MSE variando de 0,00057 a 0,00238 e  $R^2$  oscilando entre 0,96 e 0,99. Isso sugere que o modelo é estável e generaliza bem para diferentes períodos da série temporal analisada. Com o modelo previsto validado e conhecendo os dados previstos dos piores cenários de perdas que podem ocorrer no sistema estudado a gestão eficiente do sistema pode ser realizada pois, esses valores foram enviados ao servidor para que evite que essas perdas venham a ocorrer durante a operação da rede para as próximas 24 horas.

## CONCLUSÃO

A metodologia desenvolvida para o estudo, com a utilização conjunta de um protótipo de gêmeo pré-digital e de rede neural recorrente LSTM, para a previsão de perdas na rede de distribuição de água visando a gestão eficiente, foi competente pois o modelo conseguiu prever as perdas das 24 horas de operação da rede, além disso o modelo de previsão apresentou valores de validação bons. Também foi capaz de realizar a utilização eficiente do protótipo de gêmeo digital, com a comunicação ocorrendo de maneira simultânea e instantânea entre os ativos, o que possibilita a aplicação da gestão eficiente do sistema estudado.

## REFERÊNCIAS

- Associação Brasileira De Normas Técnicas. (2017). *NBR 12218: Projeto de rede de distribuição de água para abastecimento público*. Rio de Janeiro.
- Augustin, A. *WebSocket*, 2013. Disponível em: <https://pypi.org/project/websockets/#history>
- Aurélien, G. (2019) *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2ª Edição. Sebastopol: O'Reilly.

- Barbedo, M. D. G.; Silva, F. G. B., Marcondes, M. C.; Silva, A. T. Y. L.; Marques, S. M.; Lara, L. L. D.; Reis, J. A. T. (2025). *Avaliação do desempenho hidráulico de um sistema de abastecimento de água real no Sul de Minas Gerais com integração dos plugins QGISRed e processing R provider*. Revista Brasileira de Geografia Física, v. 18, n. 01, pp. 822-839.
- Bayılmış, C.; Ali, E. M.; Çavuşoğlu, U.; Küçük, K.; Sevin, A. (2022). *A survey on communication protocols and performance evaluations for Internet of Things*. Digital Communications and Networks, v.8, n.6, pp.1094-1104.
- Bonilla, C. A.; Brentan, B.; Montalvo, I.; Ayala-Cabrera, D.; Izquierdo, J. (2025). *Assessing the Impacts of Failures on Monitoring Systems in Real-Time Data-Driven State Estimation Models Using GCN-LSTM for Water Distribution Networks*. Water, v. 17, n. 46.
- Brasil. (2021). CONFEDERAÇÃO NACIONAL DOS MUNICÍPIOS. Brasil é um dos 20 países que mais perde água tratada. Ag. Senado, Brasília - DF.
- Brasil. (2023). Ministério do Desenvolvimento Regional. Secretaria Nacional de Saneamento –SNS. Diagnóstico Temático Serviço de Água e Esgoto – Visão Geral, ano de referência 2022. Brasília.
- Correia, P. V.; Dantas, L.; Guedes, L. A; Fernandes, M. (2021). *ANÁLISE DE DESEMPENHO DE REDES NEURAIS LSTM COM TÉCNICAS DE PRUNING PARA DETECÇÃO DE FALHAS EM PROCESSOS INDUSTRIALIS*. XV Simpósio Brasileiro de Automação Inteligente - SBA.
- Dui, H.; Cao, T.; Wang, F. (2025). *Digital twin-based resilience evaluation and intelligent strategies of smart urban water distribution networks for emergency management*. Resilient Cities and Structures, v. 4, n. 1, pp. 41-52.
- Fette, I; Melnikov, A. (2011). *The WebSocket Protocol, RFC 645*. Internet Engineering Task Force (IETF).
- Gemanopoulos, G.; Jowitt, P. W. (1989). *Leakage reduction by excess pressure minimization in a water supply network*. Proceedings of the Institution of Civil Engineers, v. 87, n. 2, pp. 195-214.
- Grieves, M.; Vickers, J. (2017). *Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems*. In Transdisciplinary Perspectives on Complex Systems. Springer, Cham Switzerland, pp. 85–113.
- Hochreiter, S.; Schmidhuber, J. (1997). *Long short-term memory*. Neural Computation. [S.I.], vol. 9, nº 8, pp. 1735-1780.
- Júnior, C. A. L. S.; Albuquerque, E. Q. (2017). *Monitoramento domiciliar do abastecimento de água utilizando conceitos de Internet das Coisas*. Revista de Engenharia e Pesquisa Aplicada, v.4, n.1.
- Kyriakou, M. S.; Demetriadis, M.; Vrachimis, S. G.; Eliades, D. G.; Polycarpou, M. M. (2023). *EPyT: An EPANET-Python Toolkit for Smart Water Network Simulations*. Journal of Open Source Software, v. 8, n. 92.
- Lara, L. L. D.; Silva, F. G. B.; Silva, A. T. Y. L.; Marques, S. M.; Barbedo, M. D. G.; Reis, J. A. T. (2024). *Proposal of a methodology for adjusting hydraulic parameters and pressures using variations of genetic algorithm operators for optimization and reduction of losses in water distribution networks*. Engenharia Sanitária Ambiental, v. 29.
- Madni, A.M.; Madni, C.C.; Lucero, S.D. (2019). *Leveraging digital twin technology in model-based systems engineering*. Systems, v.7, e.1.
- Nascimento, C. M.; Silva Netto, A. V.; Villanueva, J. M. M.; Macêdo, E. C. T. (2022). *Metodologia Aplicada ao Desenvolvimento de Gêmeos Digitais de Sistemas de Bombeamento de Água*. Sociedade Brasileira de Automática (SBA) - XXIV Congresso Brasileiro de Automática (CBA), Fortaleza - CE.
- Philip, S.; Marakkath, N.; Ganase, N. (2024). *Soft computing techniques for predicting the compressive strength properties of fly ash geopolymers concrete using regression-based machine learning approaches*. Journal of Building Pathology and Rehabilitation, v. 9, n. 108.
- Pompeu, M. L. F.; Nepomuceno, N. (2023). *OTIMIZAÇÃO ENERGÉTICA DA OPERAÇÃO DE BOMBAS EM REDES DE DISTRIBUIÇÃO DE ÁGUA USANDO UM GÊMEO DIGITAL NO APOIO*

- À DECISÃO. In: *ANAIOS DO SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL*, 2023, São José dos Campos. Anais eletrônicos... Campinas, Galoá.
- Porto, R. de M. (2006). *Hidráulica Básica*. 4. ed. São Carlos: EESC-USP.
- Ramos, H. M.; Morani, M. C.; Caravetta, A.; Fecarotta, O.; Adeyeye, K.; López-Jiménez, A.; Pérez-Sánchez, M. (2022). *New Challenges towards Smart Systems' Efficiency by Digital Twin in Water Distribution Networks*. Water, v.14, n.8.
- Rolle, R. P.; Monteiro, L. N.; Tomazini, L. R.; Godoy, E. P. (2022). *Detecção de vazamento em redes hidráulicas utilizando Redes Neurais de Grafos*. XXIV Congresso Brasileiro de Automática - CBA.
- Silqueira, M. G.; Silva, F. G. B.; Silva, A. T. Y. L.; Lara, L. L. D.; Marques, S. M.; Barbedo, M. D. G.; Reis, J. A. T. (2024). *CORRELAÇÃO DE PARÂMETROS HÍDRICOS E ENERGÉTICOS EM SISTEMA DE ABASTECIMENTO DE ÁGUA EM CIDADE DO SUL DE MINAS GERAIS*. Revista de Gestão Social e Ambiental, v. 8, n. 10, pp. 1-22.
- Silva, A. T. Y. L.; Silva, F. G. B.; Silva, A. C.; Reis, J. A. T.; Freitas, C. L.; Valerio, V. E. M. (2020). *Proposal of optimal operation strategy applied to water distribution network with statistical approach*. Revista Ambiente & Água, v. 15, n. 2.
- Silva, F. G. B. (2003). *Estudos de calibração de redes de distribuição de água através de algoritmos genéticos*. Tese (Doutorado em Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.
- Singh, M.; Fuenmayor, E.; Hinchy, E.; Qiao, Y.; Murray, N.; Devine, D. (2021). *Digital Twin: Origin to Future*. Applied System Innovation, v.4, n. 2.
- Sousa, D. L.; Bezerra, A. A.; Castro, M. A. H.; Neto, G. C. R.; Araujo, R. B. A. (2022). *Desenvolvimento de um modelo híbrido Migha-RNA para calibração de rugosidades absolutas em redes de distribuição de água*. Engenharia Sanitária Ambiental, v.27, n.6, pp.1199-1207.
- Syed, T.A.; Muhammad, M.A.; AlShahrani, A.A.; Hammad, M.; Naqash, M.T.(2024). *Smart Water Management with Digital Twins and Multimodal Transformers: A Predictive Approach to Usage and Leakage Detection*. Water, v. 16, n. 3410.
- Teixeira, R.; Silva, D.; Junior, H. M.; Forero, L.; Figueiredo, K.(2020). *Previsão de séries temporais de velocidade do vento utilizando Redes Neurais Artificiais e Métodos Estatísticos na Região de Arraial do Cabo - RJ*. Congresso Brasileiro de Inteligência Computacional.
- Toscano, W.; Cabral, E. L. L. (2006). *Contextualização de redes neurais recorrentes*. Exacta, São Paulo, v. 4, pp. 65-66.
- Unadkat, S. B.; Ciocoiu, M. M.; Medsker, L. R. *Recurrent neural networks: design and applications*. In: MEDSKER, L. R.; JAIN, L. C. (Ed.). ed.1, Londres: CRC, 2001.
- Walski, T. M.; Brill, E.; Downey, G.; Johannes, G.; Ian C.; Jeppson, R. M.; Lansey, K.; Lee, H. L.; Liebman, J. C.; Mays, Larry, M.; David R.; Ormsbee, L. (1987). "Battle of the Network Models: Epilogue." Journal of Water Resources Planning and Management, v. 113, n.2, pp. 191-203.
- Zanfei, A.; Brentan, B. M.; Menapace, A.; Righetti, M. (2022). *Um modelo de previsão de demanda de água de curto prazo usando memória multivariada de longo prazo e curto com dados meteorológicos*. Journal of Hydroinformatics, v. 24, n. 5, pp. 1053-1065.
- Zhao, L.; Song, Y.; Zhang, C.; Liu, Y.; Wang, P.; Lin, T.; Deng, M.; Li, H. (2019). *T-gcn: A temporal graph convolutional network for traffic prediction*. IEEE Trans. Intell. Transp. Syst., v. 21, pp. 3848–3858.

## AGRADECIMENTOS

Os autores agradecem à CAPES, ao PROAP e à União pelo apoio ao desenvolvimento da pesquisa, bem como ao Núcleo de Modelagem e Simulação em Meio Ambiente e Recursos e Sistemas Hídricos – NUMMARH.