

Metodologia Aplicada ao Desenvolvimento de Gêmeo Digital de Sistemas de Bombeamento de Água

Caio M. Nascimento, Ademar V. Silva Netto, Juan M. M. Villanueva e Euler C. T. Macêdo

Departamento de Engenharia Elétrica, Centro de Energias Alternativas e Renováveis (CEAR), UFPB, João Pessoa (PB)
(e-mails: caio.nascimento@cear.ufpb.br; ademar@cear.ufpb.br; jmauricio@cear.ufpb.br; euler@cear.ufpb.br)

Abstract: Water supply companies are always being modernized with the implementation of new technologies, such as supervisory control systems and data acquisition. With the arrival of Industry 4.0 concept, the next step is the development of Digital Twins (DT) in order to find solutions in the lowest possible time and support operators training. The studies related to DT are recent and have few applications in water supply network systems, where most part of the research are related to concepts and how it can be improved with its implementation. This article describes the steps to develop a DT in order to support decision-making process, detect anomalies and assist in the training of operators of a hydraulic plant. The study was divided into two parts, the first consists of the develop of a Digital Model, and the second of a Digital Shadow. Artificial Neural Networks were used for the Digital Model implementation, in which two different activation functions were considered, the sigmoid and ReLU, thus looking for the best result of the mean square error between the two activation functions. The best model was used in parallel with the real hydraulic plant, thus observing its performance in relation to the real data. Among the developed models, the ReLU activation function presented the best performance, being in the sequence used in Digital Shadow implementation, which even having a result with a greater error than that observed in its training and validation step, but presenting a good behavior in relation to the actual plant data. The results obtained in the Digital Model and Digital Shadow stages are relevant for the development of DT.

Resumo: As empresas de abastecimento de água estão sempre modernizando-se com implementações de novas tecnologias, como a de sistemas de controle supervisão e aquisição de dados. Com a chegada da Indústria 4.0, o próximo passo é o desenvolvimento de Gêmeos Digitais (GD), a fim de encontrar soluções no menor tempo possível e apoiar treinamentos de operadores. Os estudos relacionados à GD são recentes e possuem poucas aplicações em sistemas de redes de abastecimento de água, tendo a maior parte das pesquisas relacionadas a conceitos e de como poderá melhorar com sua implementação. Neste artigo é descrito o desenvolvimento de duas etapas iniciais para a construção de um GD com o intuito de realizar o suporte a tomada de decisão, detecção de anomalias e auxiliar no treinamento de operadores de uma planta hidráulica. A primeira etapa consiste no desenvolvimento de um Modelo Digital, e a segunda de uma sombra digital. Foram utilizadas Redes Neurais Artificiais para o desenvolvimento do Modelo Digital, no qual utilizou-se duas funções de ativação diferentes, a sigmoide e ReLU, buscando assim o melhor resultado do erro quadrático médio entre as duas funções de ativação. O melhor modelo foi utilizado em paralelo com a planta hidráulica real, observando assim seu desempenho em relação aos dados reais. Dentre os modelos desenvolvidos, o que utilizou a função de ativação ReLU obteve o melhor resultado, sendo aproveitado na implementação do sombra digital, que mesmo tendo um resultado com um erro maior do que o observado nas etapas de treinamento e validação, apresentou um bom comportamento em relação aos dados da planta real. Os resultados obtidos nas etapas do Modelo Digital e da sombra digital mostram-se relevantes para o desenvolvimento do GD.

Keywords: Industry 4.0; Digital Twins; Water pumping system; Artificial neural networks; Digital Model; Digital Shadow.

Palavras-chaves: Indústria 4.0; Gêmeos Digitais; Sistema de bombeamento de Água; Redes Neurais Artificiais; Modelo Digital; Sombra Digital.

1. INTRODUÇÃO

De toda a água presente na terra, apenas 2,5 a 2,75% são de água doce, incluindo as águas congeladas em forma de neve, umidade do solo, etc., sendo distribuída para fins comerciais, industriais, públicos e domésticos (DEEPALI e SANDIP,

2019). O sistema de distribuição de água é composto por manancial, na qual é retirada a água com vazão e qualidade adequada; captação, responsável pela retirada da água do manancial; estação elevatória, que transfere a água bruta ou tratada para a unidade seguinte; adutora, que é canalização da água que precede a rede de distribuição; a estação de

tratamento de água (ETA), que consiste na adequação da água aos padrões de potabilidade; reservatórios, responsável pela regularização das variações de adução e distribuição e condicionamento das pressões na rede de distribuição; e por último, a rede de distribuição, que é formada pelas tubulações destinadas a entregar ao consumidor final água de forma contínua, em quantidade e pressão recomendada (TSUTIYA, 2006).

Focando cada vez mais no fornecimento de água de melhor qualidade, livres de elementos e substâncias que possam afetar a saúde humana, as empresas de abastecimento de água começaram a utilizar sistemas de controle supervisão e aquisição de dados (SCADA - *Supervisory Control and Data Acquisition*) afim de controlar e gerir os sistemas de distribuição de água, permitindo o monitoramento 24 horas por dia, sete dias por semana (FRANCO, 2019).

Em busca de uma maior produtividade e eficiência do setor industrial e novas oportunidades de mercado, o governo alemão desenvolveu o conceito de fábricas inteligentes em parceria com universidades e empresas. Tais fábricas possuem alto grau de autonomia e flexibilidade, integrada a toda cadeia de valor e ciclo de vida do produto (DALENOGARE, 2018).

Essa iniciativa é chamada de Indústria 4.0, sendo uma inovação baseada na combinação de diferentes tecnologias, fazendo com que as empresas revejam a forma como gerem os seus negócios e processos, seu posicionamento na cadeia de valor, no desenvolvimento de novos produtos e sua introdução no mercado. Focando na melhoria contínua em termos de eficiência, segurança, produtividade das operações e especialmente no retorno do investimento, a Indústria 4.0 possui muitas tecnologias e tendências facilitadoras disponíveis, porém a Internet das Coisas e Serviços, Sistemas Ciber-Físicos e Big-Data são consideradas como os principais pilares da indústria inteligente. Estas tecnologias contribuem para a criação do que é o Gêmeo Digital de um processo físico, ou seja, um modelo matemático capaz de descrever o processo, o produto ou serviço para realizar análises e aplicar as estratégias da empresa (COELHO, 2016; BEVILACQUA, 2020).

Como próximo passo, as empresas de abastecimento de água buscam implementação de Gêmeos Digitais (GD), permitindo simulações dinâmicas do processo, com o intuito de melhorar suas instalações, bem como apoiar no treinamento de seus operadores, a fim de reduzir os riscos e otimizar as operações (CURL et al., 2019).

Neste trabalho é apresentado o desenvolvimento de duas etapas fundamentais para a construção de um Gêmeo Digital de um sistema de bombeamento de água, que são o desenvolvimento dos modelos digitais e seu uso como sombra digital, e que tem como objetivo final o desenvolvimento de um GD que auxiliará a detecção de anomalias, com suporte a tomada de decisão, evitando altas ou baixas pressões, e apoio ao treinamento de operadores que fazem uso da planta.

2. GÊMEOS DIGITAIS

Segundo GLAESSGEN e STARGEL (2012), um Gêmeo Digital (do inglês, *Digital Twin*) é uma simulação multifísica, multiescalar e probabilística integrada de um sistema construído e que usa os melhores modelos físicos disponíveis, atualizações de sensores, histórico, etc., para espelhar a vida de seu gêmeo correspondente.

O Gêmeo Digital possui três partes principais, que são:

- Produto físico no Espaço físico;
- Produto virtual no Espaço virtual;
- Conexões de dados e informações entre os dois produtos.

O produto virtual pode ser melhorado em relação à quantidade de informações disponíveis, adicionando características comportamentais para que possibilite não apenas a visualização do produto, mas também testá-lo quanto às capacidades de desempenho (GRIEVES, 2014).

O GD é uma reflexão em tempo real, ou seja, o espaço virtual é um espelho do espaço físico, podendo manter uma sincronização e fidelidade com espaço real. Ele possui interação e convergência no espaço físico, em que os dados gerados em várias partes no espaço físico podem se conectar entre si. Os dados obtidos em tempo real podem ser muito abrangentes, porém, conseguem ser melhor explorados e usados de forma mais completa por meio da convergência com seu histórico. O GD tem a capacidade de se atualizar em tempo real por meio da comparação do espaço virtual com o espaço real, sofrendo assim melhorias contínuas (TAO et al., 2018).

2.1 Modelo Digital, Sombra Digital e Gêmeo Digital

KRITZINGER et al.(2018) propôs que os Gêmeos Digitais fossem divididos em três categorias de acordo com seu nível de integração, como pode ser visualizado na Figura 1, que são:

- Modelo Digital: não possui nenhum tipo de integração com o objeto físico, sendo apenas uma representação digital de um objeto físico. Pode-se utilizar dados reais, porém a troca de dados é feita de forma manual;
- Sombra Digital: possui conexão com o objeto real, porém o fluxo de dados é unidirecional, sendo do objeto físico para o objeto virtual;
- Gêmeo Digital: possui conexão e troca de dados entre o objeto real e o objeto virtual, no qual o objeto físico envia dados para atualizar o objeto virtual e o objeto virtual pode fazer controle do objeto físico.

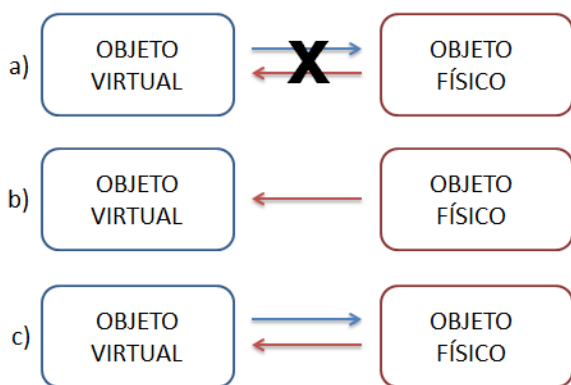


Fig. 1 a) Modelo Digital b) Sombra Digital c) Gêmeo Digital

2.2 Funcionalidades

Se o modelo for preciso, o GD pode ser utilizado para a resolução de problemas de controle complexos, porém se não for, pode-se usá-lo como controle paralelo. Como vantagens tem-se a possibilidade de usar regras predefinidas para monitorar todo o processo de operação, que pode ser tedioso e propenso a erros para o ser humano; simulação rápida e soluções de problemas, reduzindo custos e tempo; e identificação de gargalos no processo de fabricação (WANG et al., 2021).

Em relação aos sistemas de distribuição de água, o GD pode ser utilizado para o gerenciamento de pressão, simulação de operação de válvulas, previsão de demandas, otimização das configurações de bombas e válvulas, avaliação de perdas de água, análise de contaminantes em tempo real, previsão do comportamento da rede em algumas horas à frente, entre outras coisas (SINGH, 2019).

2.3 Trabalhos Relacionados

Existem algumas aplicações de GD em sistemas de abastecimento de água, como por exemplo, o da empresa Global Omnium que opera um GD na Área Metropolitana de Valência localizada na Espanha, no qual realiza a identificação de padrões, previsão de demandas e detecção de anomalias. O modelo virtual, desenvolvido no EPANET, está conectado a rede de distribuição que possui 600 sensores, com 95% de precisão em relação à vazão e 98% para a estimativa da pressão. Consegue realizar simulação do passado, presente e futuro com todas as condições de operação, dá suporte sobre o melhor tempo para manutenção e outras operações, detecção de anomalias, suporte para treinamentos. Na cidade de Eindhoven na Holanda também foi realizada a implementação de um GD da sua rede de distribuição de água, no qual utiliza dados obtidos por meio de telefones celulares para entender a dinâmica da população, junto com informações do clima, espaço utilizado e informações sobre a população que alimenta o modelo de demanda de água no SIMEDUM, e possui simulações para três tipos de eventos: a semana regular; semana quente; e períodos de férias. O GD conseguiu modelar vazamentos e

registro de válvulas incorretas, permitindo identificar áreas com pressões baixas (ALZAMORA et al., 2021).

CURL et al. (2019) falam sobre a implementação a ser feita na cidade de San Diego do programa *Pure Water San Diego* até o ano de 2035, no qual fornecerá um terço da água para a cidade. O GD busca realizar o comissionamento e operações a longo prazo como uma plataforma de treinamento de operadores, quando as bombas devem iniciar e parar e como devem ajustar a velocidade em relação a outras operações do processo e instrumentação on-line, e em relação a qualidade da água, simulando a química da água para toda a instalação.

Os trabalhos encontrados na literatura para GD de sistemas de abastecimento de água são voltados para os sistemas de distribuição de água, enquanto este trabalho concentrou-se no sistema de bombeamento de água utilizando como modelo para as simulações as redes neurais artificiais.

3. MATERIAIS E MÉTODOS

A seguir serão apresentados os materiais empregados e a metodologia desenvolvida para a implementação de duas etapas no desenvolvimento do GD de um sistema de abastecimento de pequeno porte, que consiste no modelo digital e na sombra digital.

3.1 Planta Hidráulica

Para o desenvolvimento da metodologia proposta neste trabalho foi utilizada uma bancada experimental localizada no Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) na Universidade Federal da Paraíba, que é composta por duas zonas: em amarelo temos a Zona Alta (ZONA A) e em vermelho a Zona Baixa (ZONA B), como pode ser visualizado na Figura 2.

Para o desenvolvimento das duas etapas utilizou-se do sistema hidráulico os dois reservatórios de 310 litros interligados entre si. O bombeamento da água no sistema é realizado por meio de um conjunto motobomba (CMB) e a Zona Baixa, com o sensor de pressão PT3 e a válvula proporcional CV2. Na bancada foi utilizado o inversor de frequência para o controle da velocidade do conjunto motobomba e dois dispositivos da *National Instruments*, o NI USB 6229 e o NI USB6221, para a aquisição dos dados do sensor e para controle dos atuadores.




Fig. 2 Bancada Experimental LENHS.

3.2 Métodos

O desenvolvimento para a construção do GD está dividido em três partes, no qual duas delas serão contempladas neste artigo, que são modelo digital e a sombra digital.

Para o desenvolvimento do modelo digital e da sombra digital foi utilizada a Zona Baixa da planta hidráulica, fazendo uso do conjunto motobomba, da válvula CV2 e do sensor de pressão PT3.

Utilizou-se a linguagem de programação Python na versão 3.9, uma linguagem interpretada, orientada a objetos e de alto nível. Muito atraente para o desenvolvimento rápido de aplicativos, pois possui sintaxe simples, suportando módulos e pacotes, incentivando a modularidade do programa e o reuso de código (PYTHON, 2022).

Para a comunicação com os dispositivos USB-6221 e USB-6229 foi utilizado o pacote fornecido pela *National Instruments*. Trata-se de uma Interface de Programação de Aplicação API (*Application Programming Interface*) que interage com o driver NI-DAQmx (NATIONAL INSTRUMENTS, 2021), tornando assim possível o controle dos atuadores, aquisição de dados dos sensores e posteriormente seu armazenamento.

- Modelo Digital: foram construídos modelos utilizando redes neurais artificiais *feedforward* com duas entradas, uma referente a frequência do conjunto motobomba (F_{CMB}) e outra

ao ângulo da válvula (A_{CV2}), e uma saída, referente aos dados do sensor de pressão PT3. A rede possui três camadas ocultas nas quais seus neurônios variam entre cinco e sete por camada, passando por todas as combinações possíveis, como pode ser visto na Figura 3, buscando o menor erro quadrático médio (EQM) entre os modelos, conforme definido em (1). Foram desenvolvidos modelos com dois tipos de função de ativação: sigmoide, que retornam um valor próximo de 0 para valores pequenos e próximo de 1 para valores grandes, e a ReLU (*Rectified Linear Unit*), que é a unidade linear retificada, na qual para valores negativos sua saída é 0 e para valores positivos sua saída não é alterada. O otimizador utilizado foi o Adam, no qual em um estudo comparativo para detecção de vazamentos em tubulação realizado por ARUNSURIYASAK, BOONME, PHASUKKIT (2019) apresentou um melhor resultado em relação aos otimizadores Adadelta e o RMSProp.




Fig. 3 Rede Neural da Planta Hidráulica.

$$EQM = \frac{\sum_{k=1}^p (y(k) - \hat{y}(k))^2}{p} \quad (1)$$

Os dados para o treinamento e validação do modelo possuem um total de 8940 amostras para cada uma das entradas, que são a frequência do conjunto motobomba e o ângulo da válvula CV2, e saídas, referente à pressão obtida do sensor de pressão PT3. Para obtenção dos dados foi utilizado uma rotina que varia a frequência do conjunto motobomba de 5 em 5 Hz em um intervalo de 30 a 45 Hz, e o ângulo da válvula de 15 em 15° em um intervalo de 0 a 45°, no qual quanto maior o ângulo, mais fechada a válvula estará, e foram avaliadas todas as combinações possíveis. Ao final da coleta dos dados, foram feitas quatro medições de cinco minutos cada, variando a frequência do conjunto motobomba ou o ângulo da válvula a cada minuto da medição. Foram observados possíveis erros nas medições, podendo existir valores muito baixos. Manualmente, foram verificadas médias para os valores mínimos, e posteriormente os valores que não se enquadram nessa faixa foram substituídos pela média das últimas quatro medições.

Após o tratamento dos dados, o qual consistiu na substituição dos dados com valores muito baixos ou negativos, os valores foram normalizados linearmente considerando seus valores máximos e mínimos, conforme mostrado em (2), ficando na faixa entre 0 e 1, e após a normalização, aplicou-se uma média móvel em X_n para suavizar os dados, diminuindo o efeito de ruídos que por ventura existiam.

$$x_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}; \quad (2)$$

sendo x_n o valor normalizado, x_i o valor a ser normalizado, x_{\min} é o valor mínimo das amostras a serem normalizados e x_{\max} o valor máximo das amostras do atributo a serem normalizados.

- Sombra Digital: o modelo com melhor resultado foi utilizado em paralelo ao sistema físico, no qual necessita de tratamento para ocorrer às simulações e assim posteriormente ser comparado com os dados do sistema físico, como pode ser visto na Figura 4. A saída gerará um erro, que consiste na diferença do valor real e do valor gerado pela simulação.




Fig. 4 Sombra digital da planta hidráulica.

Para avaliar o desempenho do modelo em relação ao sistema real foi utilizado o erro percentual absoluto médio (MAPE - Mean Absolute Percentual Error), o qual encontra-se apresentado em (3), permitindo o entendimento do resultado como uma média do erro entre o valor amostrado e o valor obtido pelo modelo.

$$MAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (3)$$

Em relação ao EQM, o resultado do MAPE possui menos influência dos outliers, que são amostras que costumam se distanciar das demais por possuírem valores atípicos. Porém, se o dado real for próximo a zero, pode ocorrer elevação do resultado final, apresentando um erro percentual um pouco maior como resposta.

4. RESULTADOS

A seção de resultados está dividida em três partes, que são o tratamento de dados, no qual serão apresentados os dados utilizados e seu tratamento, modelo digital, que são apresentados os modelos desenvolvidos, e por último a sombra digital, que consiste em utilizar o melhor modelo desenvolvido em paralelo com o sistema físico.

4.1 TRATAMENTO DE DADOS

Os dados para treinamento e validação foram obtidos a partir das rotinas desenvolvidas e variando a frequência do conjunto motobomba e o ângulo da válvula CV2 entre os valores de 0 a 45 Hz e 0 a 45° respectivamente, podendo ser visualizados na Figura 5, na qual observa-se em azul os valores da entrada do conjunto motobomba, em laranja o ângulo da válvula CV2, e em verde os valores obtidos da pressão do sensor de pressão PT3.




Fig. 5 Dados para treinamento.

Após verificação, constatou-se que os dados do sensor de pressão PT3 estão em uma faixa superior a 0,65 mca. De um total de 8940 amostras, 16 amostras não satisfizeram a condição, ficando abaixo do valor de 0,65 mca, sendo substituídas pela média das quatro amostras anteriores.

Como passo seguinte, foi realizada a normalização dos valores e uma suavização, com o resultado podendo ser visualizado na Figura 6.

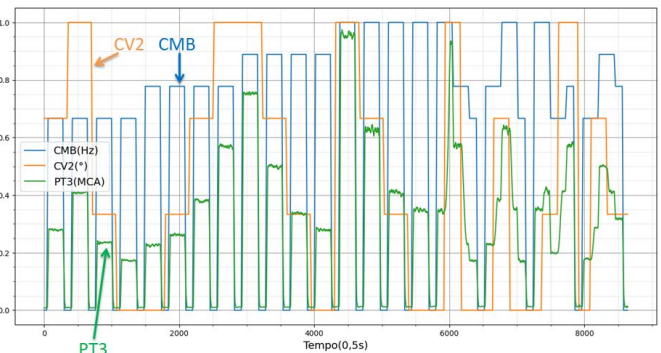


Fig. 6 Dados tratados.

4.2 MODELO DIGITAL

Para o treinamento foram utilizadas 70 épocas, número visto como suficiente para a convergência do erro de treinamento até a estabilidade, e foi escolhido o melhor modelo para cada função de ativação com base no erro quadrático médio de cada um. Após testes empíricos verificou-se que o melhor modelo da função sigmoide possui sete neurônios na primeira camada oculta, seis na segunda camada oculta e sete na terceira camada oculta. Para a função de ativação ReLU, o melhor modelo obtido possui cinco neurônios na primeira camada e seis neurônios nas camadas seguintes. Na Tabela 1 pode-se verificar o resultado do cálculo do erro quadrático médio para o melhor modelo de cada função de ativação.

Tabela 1. Resultado Erro Quadrático Médio.

	SIGMOIDE	RELU
EQM	0,0029	0,0023

Dentre os 27 modelos gerados para cada função de ativação utilizada, o melhor modelo obtido foi com a função ReLU,

obtendo um resultado 26% melhor do que o resultado encontrado na função de ativação sigmoide.

4.3 SOMBRA DIGITAL

Foi utilizado para o desenvolvimento da sombra digital o modelo com a função de ativação ReLU, pois possui o menor EQM entre os modelos de cada função. Foram feitas duas medições diferentes com cinco minutos cada, podendo variar ou não a frequência do conjunto motobomba e a angulação da válvula CV2. As Figuras 7 até 11 ilustram as medições experimentais junto com a resposta obtida da simulação para cada ação ocorrida na planta hidráulica.

O primeiro experimento começou com a frequência do CMB sendo alterado para 30 Hz, no qual, após um minuto de funcionamento, a válvula CV2 foi alterada para 45°. Passado um minuto após a mudança do ângulo da válvula CV2, a frequência o CMB foi alterada para 40 Hz. No minuto seguinte, o ângulo da CV2 foi modificado para 15°, e passado mais um minuto, o CMB foi alterado para 35 Hz, no qual permaneceu em funcionamento por mais um minuto. Os dados obtidos estão representados graficamente na Figura 7.




Fig. 7 Experimento 1.

O resultados obtidos no Experimento 1 apresentaram um bom comportamento, no qual o modelo acompanhou as operações realizadas, obtendo um resultado final do EQM de 0,4757 e MAPE de 15,29%.

O segundo experimento realizado iniciou-se com o CMB com 45 Hz, no qual, após um minuto de funcionamento, a válvula CV2 foi alterada para 15°. Com mais um minuto após a alteração na válvula CV2, o CMB foi alterado para 30 Hz. No minuto seguinte, a válvula CV2 foi alterada para 45°, onde o sistema permaneceu pelos dois minutos seguintes sem sofrer nenhuma alteração até o CMB ser desligado, como pode ser visualizado na Figura 8.




Fig. 8 Experimento 2.

O Modelo Digital também apresentou bom comportamento em relação às operações realizadas no Experimento 2, alcançando um EQM de 0,4827 e um MAPE de 18,85%.

O Experimento 3, como pode ser visualizado na Figura 9, começou com a frequência do conjunto motobomba (CMB) variando de 0 Hz para 45 Hz. O ângulo da válvula CV2, após um minuto, variou de 0° para 45°, e logo, após mais um minuto, a frequência do CMB foi alterada para 35 Hz. No próximo minuto o estado da válvula foi alterado novamente para 0°, e após mais um minuto, a frequência do CMB foi modificada para 30 Hz, a qual permaneceu por um minuto antes de ser desligada, finalizando assim o terceiro experimento.




Fig. 9 Experimento 3.

O Experimento 3 obteve um EQM de 0,7565 e um MAPE de 19,76%, apresentando um erro em regime permanente de 10,8% para o conjunto motobomba com 45 Hz e o ângulo da válvula CV2 com 45°.

O Experimento 4, como pode ser visto na Figura 10, começou com o CMB com uma frequência de 35 Hz, no qual, após um minuto de funcionamento, a válvula CV2 foi alterada para o ângulo de 30°, e após mais um minuto de funcionamento, o CMB foi alterado para 45 Hz. No minuto seguinte a válvula CV2 foi totalmente aberta. Passado um minuto da alteração da válvula CV2, o CMB foi alterado para 30 Hz, em que permaneceu durante 1 minuto de funcionamento antes de ser desligado.




Fig. 10 Experimento 4.

O comportamento do Modelo Digital em relação às operações realizadas Experimento 4 apresentaram um bom resultado, com um EQM de 0,3229 e MAPE de 13,94%

O Experimento 5 realizado foi iniciado com o CMB com uma frequência de 40 Hz. Após um minuto de funcionamento, a válvula CV2 foi alterada para 45°, e no minuto seguinte, o CMB foi alterado para 30 Hz. Passado mais um minuto após a última alteração, a válvula CV2 foi alterada para 30°, e no minuto seguinte, o CMB foi alterado para 35 Hz, no qual permaneceu em funcionamento por um minuto antes de ser desligado, como pode ser visualizado na Figura 11.




Fig. 11 Experimento 5.

Em relação às operações realizadas no Experimento 5, o Modelo Digital apresentou um erro em regime permanente alto, tendo como resultado final um EQM de 0,989 e um MAPE de 18,85%, com um erro em regime permanente de 22,57% para a operação com o conjunto motobomba a 35 Hz e a válvula CV2 com 30°.

O erro quadrático médio e o erro percentual absoluto médio da saída da planta real e da saída do modelo para cada medição experimental podem ser vistos na Tabela 2.

Tabela 2. Resultados dos Experimentos

	EXP. 1	EXP. 2	EXP. 3	EXP. 4	EXP. 5
EQM	0,4757	0,4827	0,7565	0,3229	0,989
MAPE	15,29%	18,85%	19,76%	13,94%	18,85%

Os experimentos foram realizados sem fazer nenhum tratamento com os dados obtidos da planta real, observando

assim, o desempenho do modelo em relação aos dados sem tratamento e com a presença de ruídos.

O Experimento 4 obteve o melhor resultado, com uma resposta 206% melhor do que o pior resultado do erro quadrático médio, que foi o da medição experimental 5, no qual observa-se que o modelo necessita de mais dados de treinamento para obter um melhor desempenho.

Observa-se nos resultados que houve um EQM maior para o Experimento 5 do que no Experimento 3, que obteve um valor de MAPE um pouco maior, mesmo o Experimento 5 tendo o maior resultado para o MAPE em regime permanente. Isso ocorre devido o EQM ter uma maior influência no valor final para os resultados em que o erro entre a amostra e o simulado é superior a um, valor este encontrado durante operações do Experimento 5. Em relação ao MAPE, mesmo possuindo um MAPE em regime permanente elevado para uma operação, indica que houve uma grande aproximação do valor encontrado e do simulado para as outras operações, diminuindo assim o valor final do MAPE.

5. CONCLUSÕES

Para o desenvolvimento de um bom modelo é necessário que exista um pré-processamento dos dados a serem utilizados, retirando dados com valores atípicos e buscando diminuir a influência dos ruídos. Para isso foram substituídos valores considerados abaixo de uma determinada faixa por média de seus valores vizinhos e foi utilizada a média móvel para diminuição dos ruídos, obtendo assim dados adequados para serem utilizados.

Os modelos foram construídos com redes neurais artificiais de forma dinâmica utilizando diferentes tipos de combinação de neurônios e funções de ativação em busca dos melhores modelos, no qual tiveram um erro quadrático médio em relação aos dados reais abaixo de $3,0 \times 10^{-3}$, sendo o modelo digital com a função de ativação ReLU e 5 neurônios na primeira camada oculta e 6 nas duas camadas ocultas seguintes o melhor resultado obtido.

Os resultados apresentados durante a realização das medições experimentais, a sombra digital obteve um bom comportamento em relação à planta real, na qual se conseguiu realizar a predição de dados para acompanhar curvas de abertura e fechamento de válvulas e mudanças na frequência do conjunto motobomba. A predição obteve para algumas operações um valor muito próximo do real, porém divergiu em outras, como no Experimento 5, chegando a valores em regime permanente de 22,57%, mostrando assim ainda a necessidade de mais dados para seu treinamento ou da constante atualização do modelo digital sempre que houver essa diferença entre o valor obtido e o simulado.

Os resultados obtidos são promissores para o desenvolvimento do GD voltado para a detecção de anomalias na planta hidráulica, evitar operações que ponham em risco a integridade da planta hidráulica ou o uso como suporte para treinamentos de operadores.

AGRADECIMENTOS

Agradecemos a Universidade Federal da Paraíba, em especial ao Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) por disponibilizar suas instalações para execução de testes de validação dos experimentos.

REFERÊNCIAS

- ALZAMORA, Fernando Martínez et al (2021). Digital Twins-A new paradigm for water supply. *HydroLink 2021-2 Artificial Intelligence*.
- ARUNSURIYASAK, Peerachai; BOONME, Phattraporn; PHASUKKIT, Pattarapong. Investigation of deep learning optimizer for water pipe leaking detection. *2019 16th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). IEEE*, 2019. p. 85-88.
- BEVILACQUA, Maurizio et al. (2020). Digital twin reference model development to prevent operators' risk in process plants. *Sustainability*, v. 12, n. 3, p. 1088.
- COELHO, Pedro Miguel Nogueira (2016). Rumo à Indústria 4.0. *Dissertação(Mestrado) - Departamento de Engenharia Mecânica*. Universidade de Coimbra, Coimbra, 2016.
- CURL, Jason M. et al. (2019). Digital twins: The next generation of water treatment technology. *Journal-American Water Works Association*, v. 111, n. 12, p. 44-50.
- DALENOGARE, Lucas Santos (2018). A Indústria 4.0 no Brasil: Um Estudo dos Benefícios Esperados e Tecnologias Habilitadoras. *Dissertação(Mestrado) - Programa de Pós-Graduação em Engenharia de Produção*. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.
- DEEPALI, V.; SANDIP, M (2019). Investigating effect of pipe closure as pressure deficient condition on water distribution network using EPANET. *5th International Conference On Computing, Communication, Control And Automation (ICCUBEA)*, pp. 1-7.
- FRANCO, Daniel José et al(2019). A Review on Current and Old SCADA Networks Applied to Water Distribution Systems. *2019 First International Conference of Intelligent Computing and Engineering (ICOICE). IEEE*, p. 1-11.
- GLAESSGEN, Edward; STARGEL, David (2012). The digital twin paradigm for future NASA and US Air Force vehicles. *53rd AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics and materials conference 20th AIAA/ASME/AHS adaptive structures conference 14th AIAA*. p. 1818.
- GRIEVES, Michael. Digital twin: manufacturing excellence through virtual factory replication. *White paper*, v. 1, p. 1-7, 2014.
- KRITZINGER, Werner et al. (2018). Digital Twin in manufacturing: A categorical literature review and classification. *IFAC-PapersOnLine*, v. 51, n. 11, p. 1016-1022.
- NATIONAL INSTRUMENTS (2021). NI-DAQmx Python Documentation. NATIONAL INSTRUMENTS, c2021. Disponível em: <https://nidaqmx-python.readthedocs.io/en/latest/>. Acesso em: 15 set. 2021.
- PYTHON(2022). What is Python? Executive Summary. PYTHON, c2022. Disponível em: <https://www.python.org/doc/essays/blurb/>. Acesso em: 26 jan. 2022.
- SILVA, Fabrício Roosevelt Melo da (2017). Implantação e Desenvolvimento de uma Rede de Automação Industrial e Sistema SCADA para Estação de Tratamento de Água Purificada. *Dissertação(Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica e de Computação*. Universidade Federal do Rio Grande do Norte, Natal, 2017.
- SINGH, Keshvinder. (2019). Real Time Digital Twin of Water Distribution Network. *LINKENDIN, 2019*. Disponível em: <https://www.linkedin.com/pulse/real-time-digital-twin-water-distribution-network-keshvinder-singh/>. Acesso em: 07 jan.2022.
- TAO, Fei et al. (2018). Digital twin-driven product design, manufacturing and service with big data. *The International Journal of Advanced Manufacturing Technology*, v. 94, n. 9, p. 3563-3576.
- TSUTIYA, Milton T(2006). *Abastecimento de água*, ABES, São Paulo.
- WANG, Yutong; CAO, Yansong; WANG, Fei-Yue (2021). Anomaly Detection in Digital Twin Model. *2021 IEEE 1st International Conference on Digital Twins and Parallel Intelligence (DTPI)*, pp. 208-211.