



XXX Congresso Nacional de Estudantes de Engenharia Mecânica
19 a 23 de agosto de 2024, Uberaba, Minas Gerais, Brasil

PONTO DE MÁXIMA EFICIÊNCIA DE UM SISTEMA DE BOMBEAMENTO DE ÁGUA UTILIZANDO MODELO NEURO-FUZZY

Hugo A. M. Moreira, HugoMarinho93@outlook.com¹
Juan. M. Villanueva, jmauricio@cear.ufpb.br²
Heber P. Gomes, Heberp@uol.com.br³

¹ Universidade Federal da Paraíba, Departamento de Engenharia Mecânica, LENHS, João Pessoa, Brasil.

² Universidade Federal da Paraíba, Departamento de Engenharia Elétrica, LENHS, João Pessoa, Brasil.

³ Universidade Federal da Paraíba, Departamento de Engenharia Civil, LENHS, João Pessoa, Brasil.

Resumo. A caracterização do rendimento desempenha um papel crucial na análise das medidas de eficiência energética. Para sistemas de bombeamento que, comumente, utilizam a configuração série/paralelo, encontrar a melhor configuração de trabalho representa um ganho significativo na redução do consumo de energia. Este trabalho propõe o desenvolvimento de um modelo computacional global utilizando a técnica Neuro-Fuzzy para a caracterização do rendimento, visando localizar o Ponto de Máxima Eficiência Energética e, conseqüentemente, racionalizar o consumo energético dos sistemas de bombeamento. O método foi aplicado em um sistema composto por um conjunto motobomba (CMB) automatizado e controlado por um controlador inteligente Neuro-Fuzzy, cuja função é manter as pressões de serviço nos set-points por meio do controle da rotação do CMB. Para desenvolver um banco de dados de treinamento e validação e modelar o sistema, foram realizados ensaios em toda a região de operação. Os resultados da modelagem demonstram a capacidade de caracterização da eficiência do sistema utilizando dados amostrais, apresentando ajustes satisfatórios em toda a região de operação. Além disso, a análise do modelo revelou regiões em que o sistema pode operar com rendimento até 305% superior em comparação com cenários de máxima capacidade do CMB.

Palavras-chave: Abastecimento de água, Sistemas de bombeamento; Controle Inteligente; Eficiência energética.

Abstract. The characterization of performance plays a crucial role in analyzing energy efficiency measures. For pumping systems that commonly use the series/parallel configuration, finding the best operating setup represents a significant gain in reducing energy consumption. This study proposes the development of a global computational model using the Neuro-Fuzzy technique for performance characterization, aiming to locate the Point of Maximum Energy Efficiency and, consequently, rationalize the energy consumption of pumping systems. The method was applied to a system consisting of an automated pump set controlled by an intelligent Neuro-Fuzzy controller, whose function is to maintain service pressures at set-points through CMB rotation control. To develop a training and validation database and model the system, tests were conducted throughout the operating range. The modeling results demonstrate the system's efficiency characterization capability using sample data, showing satisfactory adjustments across the entire operating range. Furthermore, model analysis revealed regions where the system can operate with up to 305% higher efficiency compared to scenarios with maximum CMB capacity.

Keywords: Water supply; Pumping System; Intelligent control; Energy efficiency.

1. INTRODUÇÃO

Os sistemas hidráulicos desempenham um papel crucial na sociedade moderna, especialmente em processos industriais, onde são essenciais para o controle de processos e a geração/transmissão de energia por fluidos pressurizados (Diniz *et al.*, 2015). Além disso, eles são fundamentais no abastecimento de água para uso doméstico, industrial e público, embora consumam uma quantidade significativa de energia elétrica, representando aproximadamente 3% do consumo mundial, com os sistemas de bombeamento responsáveis por até 90% desse total (Gomes, 2019). Diante disso, há uma busca por sistemas mais eficientes e sustentáveis, com a automação sendo uma estratégia importante para reduzir o consumo energético. Nos períodos de baixa demanda, o sistema de bombeamento, projetado para operar em velocidade nominal, fornece à rede de água uma pressão excessiva, resultando em aumento do consumo de energia e maior probabilidade de rompimento e vazamento das tubulações. A automação se torna essencial diante das flutuações na demanda de água ao longo do dia, garantindo a manutenção da pressão em níveis ideais por meio do controle da rotação dos CMBs e das válvulas eletrônicas. (Carvalho, 2012; Mendonça, 2016; Salvino, 2016; Oliveira, 2017; Barros *et al.*,

2017; Moreira *et al.*, 2019). No entanto, esses métodos, embora eficazes na manutenção das pressões de serviço, não abordam diretamente a otimização energética, carecendo de métodos específicos para reduzir significativamente o consumo energético.

Com o avanço das técnicas computacionais, a matemática convencional tornou-se obsoleta na modelagem e no projeto de muitos sistemas dinâmicos não-lineares. Os métodos computacionais permitem utilizar algoritmos para otimizar o gasto energético através de técnicas de identificação de sistema, construindo modelos dinâmicos baseados em dados medidos (Ljung, 2017). O desenvolvimento de modelos computacionais capazes de prever a performance, localizar o Ponto de Máxima Eficiência Energética (PMEE) ou encontrar o Ponto de Máxima Potência (MPPT) é crucial para aumentar a eficiência energética de sistemas dinâmicos. O rendimento dos CMB é um aspecto técnico e energético importante no projeto e na operação de sistemas de bombeamento e distribuição de água, contudo, varia sob diversas condições ou cenários de operação. Ademais, a obtenção do modelo computacional está associada à sua importância para o estudo, otimização e análise dos sistemas e no projeto de controladores mais eficientes.

Trabalhos foram desenvolvidos para caracterizar a eficiência energética de CMBs com modelos matemáticos algébricos. Vodovozov *et al.* (2016) criaram um banco de dados tabularizado da eficiência estimada para a operação eficiente de um sistema de bombeamento, usando modelos analíticos baseados nas leis de afinidade do CMB, considerando variações de vazão e pressão de recalque. Fontanella *et al.* (2020) também abordaram esse tema, modelando a eficiência de uma bomba que opera como turbina para produção de energia, validando o modelo com dados experimentais. No entanto, os modelos polinomiais ou regressivos oferecem ajustes precisos apenas localmente, exigindo múltiplos modelos para diferentes demandas ou condições de operação, o que pode ser estafante. Pequenas alterações nos parâmetros podem tornar a função matemática obsoleta (Aguirre, 2017 e Pilonetto *et al.*, 2023).

Contudo, o uso de técnicas de inteligência artificial possibilita o desenvolvimento de modelos globais com bons ajustes para todos os casos de operação do sistema. Diversos estudos (Galhardo, 2003; Kilic *et al.*, 2012; Salvino, 2016; Neto, 2018; Cavalcanti *et al.*, 2018 e Pilonetto *et al.*, 2023) focaram na análise computacional de sistemas dinâmicos utilizando inteligência computacional para obter um modelo global do sistema e destacaram a importância de descrever suas características. A aplicação de técnicas inteligentes, como Neuro-Fuzzy, permitiu a modelagem precisa de sistemas não-lineares e multivariáveis. No entanto, a modelagem energética ou do rendimento de sistemas de bombeamento de água não foram abordados nesses estudos.

Por outro lado, alguns estudos concentraram-se em prever a performance e localizar o PMEE ou o MPPT de sistemas dinâmicos usando Neuro-Fuzzy ou Redes Neurais Artificiais (RNA). Esen *et al.* (2008) modelaram uma bomba de calor em um sistema de armazenamento térmico com Neuro-Fuzzy, alcançando altos valores do coeficiente de variância (R^2) na validação cruzada. Sun *et al.* (2015) obtiveram resultados satisfatórios de R^2 ao usar RNA e Neuro-Fuzzy para prever o rendimento de bombas térmicas de sistemas de resfriamento. Kharb *et al.* (2014) e Belhachat e Larbes (2017) buscaram o MPPT global em sistemas de energia fotovoltaica com Neuro-Fuzzy. Shabaan *et al.* (2018) usaram Neuro-Fuzzy para encontrar o MPPT em um sistema de bombeamento de água fotovoltaico, resultando em um aumento significativo no rendimento médio. Justesen e Andreasen (2015) determinaram a temperatura ótima de operação de uma célula de combustível de metanol com Neuro-Fuzzy e algoritmos de otimização. Zhang *et al.* (2015) usaram RNA para prever o consumo energético de um sistema de bombeamento em paralelo, resultando em aumento do rendimento com redução do consumo de energia em até 33%. Rossi e Renzi (2018) empregaram RNA para encontrar o Best Efficiency Point (BEP) de uma turbina e uma bomba, destacando sua aplicabilidade em outros sistemas hidráulicos.

Assim, diante da limitação dos modelos polinomiais ou regressivos, que são locais e exigem múltiplos modelos para cada ponto de operação, este estudo justifica a escolha do Neuro-Fuzzy por possibilitar o desenvolvimento de um modelo global. Esta técnica destaca-se pela robustez na identificação de características não-lineares e pela capacidade de generalização. Portanto, o objetivo deste trabalho é empregar o Neuro-Fuzzy para desenvolver um modelo global do rendimento de um sistema de bombeamento de água, permitindo caracterizá-lo em busca do PMEE. A metodologia proposta visa não apenas à modelagem, mas também à aplicação prática na otimização energética, incluindo estratégias de arranjos série/paralelo dos CMB, com uma abordagem mais ampla e eficiente na busca pela racionalização energética.

2. ARTIFICIAL NEURAL FUZZY INFERENCE SYSTEM

O método Neuro-Fuzzy (NF) representa uma abordagem híbrida que combina as características das redes neurais artificiais (RNA) com os princípios da lógica Fuzzy. As principais vantagens desta técnica residem na sua capacidade de aprendizado, adaptabilidade e generalização, esta última caracterizada pela habilidade de modelar pontos de operação não previamente treinados. Além disso, o NF oferece a vantagem de gerar um banco de regras similar ao que ocorre com a lógica Fuzzy, lidar eficientemente com dados imprecisos e ruidosos, e modelar sistemas não-lineares de maneira robusta.

A estrutura do algoritmo NF consiste em cinco camadas, cada uma desempenhando uma função específica durante o processo de treinamento (Fig. 1). Na primeira camada, calcula-se o grau de pertinência das entradas em relação aos valores ou termos linguísticos associados a cada nó. Na segunda camada, cada nó representa uma regra e avalia o grau de atendimento do consequente da regra, ou seja, as implicações das premissas. A terceira camada é responsável pela normalização do vetor de entrada. Na quarta camada, as saídas dos neurônios são determinadas pelo produto dos valores dos consequentes das regras. Por fim, na última camada, calcula-se a saída correspondente. A função gaussiana é

comumente usada como função de ativação dos neurônios. Ela é uma função de base radial que produz uma saída suave e contínua, e é especialmente útil para modelar relações complexas e não lineares entre entradas e saídas em problemas de aprendizado de máquina (Haykin, 2009).

$$f(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (1)$$

Onde x é a entrada para o neurônio, c é o centro da gaussiana, representando o ponto em que a função atinge seu valor máximo, e σ é o desvio padrão, controlando a largura da gaussiana. Essa função produz uma curva de sino simétrica em torno do ponto c , com valores de saída decrescentes à medida que a distância de x em relação a c aumenta. Quanto maior o valor de σ , mais larga será a curva, resultando em uma transição mais suave entre as regiões de ativação e inativa. Na prática, os pesos e os centros das funções gaussianas são ajustados durante o treinamento da RNA para otimizar o desempenho do modelo em relação aos dados de entrada e saída disponíveis. Para uma revisão detalhada sobre NF, recomenda-se consultar Walia *et al.* (2015).

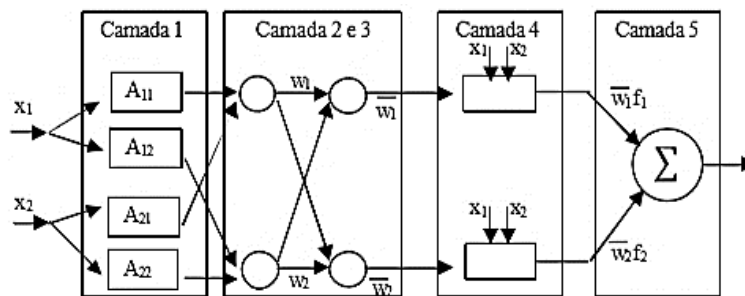


Figura. 1. Estrutura do algoritmo do Neuro-Fuzzy utilizada (Fonte: Walia *et al.*, 2015).

3. METODOLOGIA

3.1 Sistema Experimental

Este estudo utilizou uma bancada experimental (Fig. 2) equipada com um Sistema de Supervisão e Aquisição de Dados (SCADA) da National Instruments (NI USB-6229), responsável pela aquisição de dados da planta e pelo controle do conversor de frequência e da Válvula Eletrônica Redutora de Pressão (VRP). O conversor de frequência da Schneider Electric (ALTIVAR 31) ajusta a velocidade do CMB, modelo CAM W10 da DANCOR com 5 HP. A VRP (ARB24-SR) é comandada pelo supervisor desenvolvido na plataforma LABVIEW, variando o consumo de água e as pressões de serviço para manter os set-points desejados. O sensoriamento é realizado por três transdutores de pressão (Druck PTX 7217), um transdutor de vazão eletromagnético (VMS Pro 038), além de sinais enviados pelo conversor de frequência para leitura da potência ativa do CMB e pela VRP para indicar seu ângulo de abertura.




Figura 2. Esquema do sistema de bombeamento experimental (Fonte: Autoria própria).

A bancada consiste em um CMB operando "afogado", bombeando água de retorno para o reservatório. A VRP ajusta a curva da tubulação verticalmente, alterando a demanda de água e permitindo que o controlador encontre um novo ponto de equilíbrio controlando a velocidade das bombas.

3.2 Ensaios Experimentais

Foram realizados ensaios experimentais abrangendo toda a região de operação através da manipulação de duas variáveis de entrada (Frequência e Ângulo da VRP) e do monitoramento de três variáveis de saída (Potência ativa, Vazão e Pressão), de acordo com a Tabela 1 e esquematizada na Fig. 3. A Tabela 1 resume as variáveis modeladas, o seu intervalo global e o intervalo de variação utilizado nos experimentos para o desenvolvimento do banco de dados. Para evitar o efeito *aliasing*, utilizou-se uma frequência de amostragem igual a 20 Hz, superior ao critério de Nyquist (1932) que seria de 9 amostras/s, pois o efeito *aliasing* ainda estava presente nesta frequência de amostragem. ⁽¹⁾ Os valores são escolhidos aleatoriamente dentro deste intervalo. O rendimento é dado pela relação entre pressão, vazão e potência elétrica do CMB conforme a Eq. (2).

Tabela 1. Descrição das variáveis utilizadas nos ensaios (Fonte: Autoria própria).

Dados	Descrição
Variáveis de entrada	f_1 e Φ_{VRP}
Variáveis de saída	P_1 , Q_1 e PT_5
Intervalo global de operação das variáveis de entrada	$20 < f_1 < 50 \text{ Hz}$ $0 < \Phi_{VRP} < 90^\circ$
Delta de variação das variáveis de entrada ⁽¹⁾	$3 < \Delta f_1 < 5 \text{ Hz}$ $\Delta \Phi_{VRP} = 5^\circ$
Frequência de amostragem	20 amostras/s

$$\eta = \frac{\gamma * PT * Q}{P} \tag{2}$$

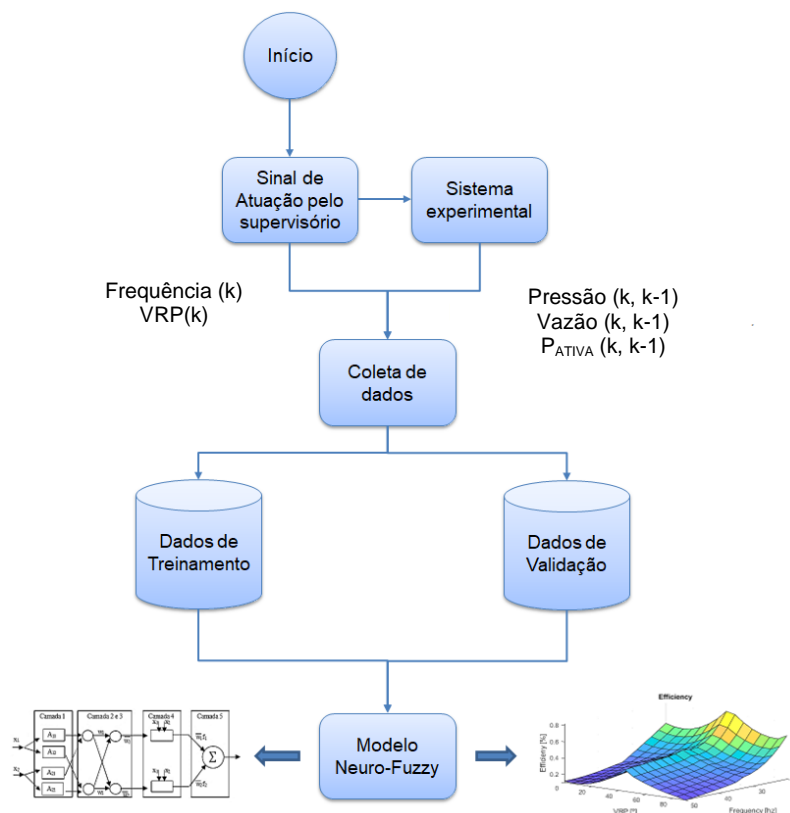


Figura 3. Fluxograma do desenvolvimento do Modelo NF (Fonte: Autoria própria).

4. RESULTADOS

Nesta seção, apresentamos os resultados da caracterização da eficiência do sistema de bombeamento. Inicialmente, conduzimos uma análise detalhada da variação da frequência para obter modelos polinomiais locais em cada faixa de

frequência e vazão, de forma individualizada. Em seguida, direcionamos o foco para o modelo global desenvolvido com o auxílio do NF. Neste modelo, as duas variáveis de entrada (rotação do CMB e demanda) e as variáveis de saída (rendimento, conforme definido pela Eq. (1)) são modeladas de forma simultânea e integrada. Este procedimento permite uma compreensão abrangente e holística do comportamento do sistema de bombeamento, fornecendo insights valiosos para otimização e controle eficazes.

4.1 Influência da frequência no rendimento

A análise polinomial da frequência em relação ao rendimento revela as características do regime operacional do sistema de bombeamento. A Figura 4 apresenta as curvas de rendimento para três condições de demanda de água, controladas pela abertura da VRP. Observa-se que os modelos polinomiais locais oferecem bons ajustes apenas em regiões específicas. No entanto, quando se busca um modelo global para uma ampla gama de condições operacionais, os modelos polinomiais são inadequados. Ao comparar o modelo global desenvolvido com NF com os modelos polinomiais, percebe-se que estes últimos proporcionam bons ajustes. No entanto, para esta análise, foi necessário desenvolver dois modelos polinomiais. Portanto, a utilização do NF é justificável, pois permite a obtenção de um modelo global multivariável capaz de fornecer o rendimento em qualquer condição de operação.

Além disso, a análise revela que, nessas circunstâncias, os pontos de máxima eficiência estão associados a baixas frequências de operação (Figura 4). No entanto, operar em frequências baixas e significativamente abaixo da capacidade nominal do equipamento pode resultar em subutilização. Portanto, a determinação do ponto de operação ideal deve considerar critérios de otimização que visem minimizar o consumo de energia.




Figura 4. Influência da frequência no rendimento do CMB (Fonte: Autoria própria).

4.2 Influência da demanda no rendimento

Sistemas de abastecimento de água enfrentam demanda variável, exigindo controle preciso dos CMBs. Para avaliar o rendimento em operações reais, este estudo ajustou a abertura da VRP para simular variações na demanda, mantendo a pressão de serviço constante em 10 metros de coluna de água (mca). Essa abordagem possibilitou uma análise precisa do desempenho, contribuindo para estratégias eficazes de controle e eficiência energética.




Figura 5. Influência da demanda no rendimento do CMB (Fonte: Autoria própria).

A Figura 5 mostra o rendimento do CMB diante da variação da demanda. Destaca-se o elevado ajuste proporcionado pelos modelos polinomiais locais, mesmo em comparação com o modelo global NF desenvolvido. É evidente que para avaliar o rendimento de forma abrangente ou com mais faixas de frequência, seriam necessários inúmeros modelos polinomiais, o que tornaria a análise exaustiva. Por fim, nota-se que uma demanda média resulta na máxima eficiência do sistema. Assim, o CMB atinge o máximo rendimento ao operar com demandas médias de vazão em pressão fixada em 10 mca.

4.3 Caracterização global do rendimento com NF

O NF demonstra robustez na modelagem de sistemas não-lineares, como evidenciado neste trabalho ao modelar toda a região de operação do sistema com dados amostrais de algumas regiões, indicando sua capacidade de generalização. A Figura 6 ilustra os dados amostrais utilizados no treinamento do modelo. Durante a coleta de dados, variou-se as entradas, conforme detalhado na Tabela 1, e monitorou-se as saídas correspondentes. O gráfico do rendimento revela a presença de valores anômalos, representados por picos, devido a ruídos no sistema de aquisição de dados. No entanto, o NF demonstra excelente capacidade para modelar dados imprecisos e ruidosos, dentro de certos limites.

Os elementos gráficos fornecem uma interpretabilidade significativa dos sistemas dinâmicos. Em hidráulica, variáveis como pressão, fluxo e demanda são continuamente monitoradas para o suprimento de energia ou controle de processos. No contexto das Funções de Pertinência (MF) dos conjuntos Fuzzy, adotamos cinco MF triangulares para cada variável de entrada. Essa estrutura foi selecionada devido à sua ótima relação entre o Erro Quadrático e o custo computacional, conforme destacado por Ljung e Glad (1994).

A estrutura Neuro-Fuzzy do modelo global consiste em cinco camadas, com uma única camada de neurônios e um total de 25 regras (Fig. 7(a)). O NF combina as vantagens das técnicas Neural e Fuzzy, resultando em uma metodologia de análise altamente interpretável. A Figura 7(b) mostra a superfície de resposta do modelo global obtida com o NF, destacando a inter-relação das variáveis do sistema. A análise revela que o rendimento máximo ocorre em baixas rotações e demandas médias de água, com regiões de máximos locais de eficiência. O sistema pode alcançar até 305% de eficiência superior em algumas regiões. A análise da Figura 8 oferece uma interpretabilidade aprimorada das condições operacionais do sistema de bombeamento. O que sugere a vantagem de manter um número específico de CMBs em arranjo paralelo, operando com demandas médias de vazão para economia de energia elétrica. Além disso, a explicação para o rendimento ser maior operando com demandas médias pode estar atribuída à redução da perda de carga na tubulação e conexões, resultado das menores vazões hidráulicas, e consequentemente, menores velocidades.

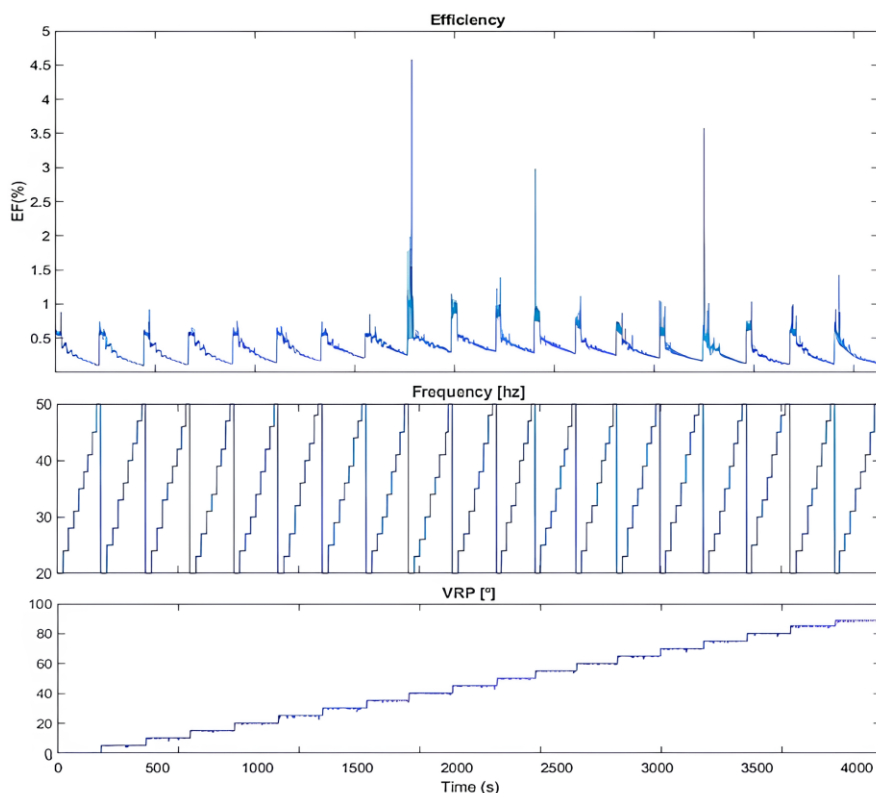


Figura 6. Dados de treinamento do modelo global NF (Fonte: Autoria própria).

Para validar o modelo global NF, são utilizados indicadores de desempenho como o Erro Médio Quadrático Normalizado (NRMSE), a Raiz do Erro Médio Quadrático (RMSE), o Erro Final de Predição (FPE) e o Percentual de

Ajuste. Os resultados obtidos estão apresentados na Tabela 2, destacando-se o alto fator de ajuste e o baixo RMSE, evidenciando a eficácia da técnica Neuro-Fuzzy na modelagem de sistemas dinâmicos não-lineares.




Figura 7. Estrutura Neural do modelo global NF (a) e Superfície do modelo global (b) (Fonte: Autoria própria).

Tabela 2. Dados de performance do modelo global.

Model	RMSE	NRMSE	FPE	Fit (%)
NF	0.14	0.1e-6	3.3e-7	99.86

5. CONCLUSÕES

Este trabalho apresentou um método para caracterizar o rendimento global de sistemas de bombeamento de água utilizando a técnica Neuro-Fuzzy, com o objetivo de desenvolver estratégias de controle para arranjos de bombeamento em série ou paralelo. O uso do NF visa superar as limitações dos modelos polinomiais, que, embora sejam facilmente obtidos, requerem muitas equações para descrever o comportamento global do sistema, tornando sua aplicação inviável em muitos casos. O NF permite a obtenção de um único modelo global multivariável do sistema, simplificando sua análise, simulação e otimização.

A análise do modelo revela que o ponto de máximo rendimento ocorre quando o sistema opera com vazões médias. Assim, pode-se conceber um projeto com mais bombas operando em arranjos série/paralelo para evitar um maior consumo de energia. No entanto, essa estratégia exigirá um investimento inicial mais elevado na aquisição de equipamentos, requerendo uma análise financeira específica para cada caso. Esta metodologia pode ser aplicada em sistemas reais de bombeamento já automatizados ou em sistemas hidráulicos/pneumáticos que experimentam variações de demanda. Suas vantagens incluem um tempo de projeto reduzido, precisão e economia de energia.

6. REFERÊNCIAS

- Aguirre, L. A.. (2017). Introdução à Identificação de Sistemas. 4ª edição. Editora UFMG. ISBN: 9788542300796.
- Barros Filho, E. G.; Salvino, L. R.; Bezerra, S. T. M.; Salvino, M. M.; Gomes, H. P., (2017). Intelligent system for control of water distribution networks. *Water Science & Technology: Water Supply*, p. 1-12, 2017.
- Belhachat, F., Larbes, C. (2017). Global maximum power point tracking based on ANFIS approach for PV array configurations under partial shading conditions. *Renewable and Sustainable Energy Reviews*, 77, 875–889. doi: 10.1016/j.rser.2017.02.056.
- Carvalho, P. S. O. Controle para bombeamento distribuído com vistas à minimização dos custos energéticos aplicado a sistemas de abastecimento de água, 2012. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2012.
- Cavalcanti, D. M. J., Villanueva, J. M., Gomes, H. P., (2018). Modelagem de um sistema de bombeamento para o controle de vazão por conversor de frequência baseado na teoria de identificação de sistemas. 10.20906/CPS/CBA2018-0313.
- Coutinho, F. A. B., Chigueru, T., Melo, R. O. Modelagem de um sistema de bombeamento fotovoltaico utilizando Redes Neurais Artificiais e comparativo com modelagem tradicional. VII Congresso Brasileiro de Energia Solar, 2018.
- Diniz, A. M. F., Fontes, C. H. O., Costa, C. A., Ferreira, A. M. S., Santos, P. I. D., (2015). Improvements In Water Supply Systems Based On Optimization And Recognition Of Consumption Patterns. *Journal of Engineering Science and Technology*, volume 10, n. 5, pages 571–590, 2015.
- Esen, H., Inalli, M., Sengur, A., & Esen, M. (2008). Predicting performance of a ground-source heat pump system using fuzzy weighted pre-processing-based ANFIS. *Building and Environment*, 43(12), 2178–2187. doi: 10.1016/j.buildenv.2008.01.002.

- O. Fecarotta, A. Carravetta, M. C. Morani, and R. Padulano. Optimal pump scheduling for urban drainage under variable flow conditions. *Resources*, 7:73, 11 2018.
- Galhardo, M. A. B., Costa, C. T., Pinho, J. T., Barra, W. Utilização de um sistema Neuro-Fuzzy para modelagem de cargas não-lineares em sistemas elétricos de potência, 2003.
- Gomes, H. P., (2019). Abastecimento de Água. João Pessoa: LENHS/UFPB, 2019.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. 3rd Edition. Prentice Hall.
- Hyndman R.J., Koehler A.B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*. Volume 22, Issue 4, Pages 679-688.
- Justesen, K. K., & Andreasen, S. J. (2015). Determination of optimal reformer temperature in a reformed methanol fuel cell system using ANFIS models and numerical optimization methods. *International Journal of Hydrogen Energy*, 40(30), 9505–9514. doi:10.1016/j.ijhydene.2015.05.085
- Kharb, R. K., Shimi, S. L., Chatterji, S., & Ansari, M. F. (2014). Modeling of solar PV module and maximum power point tracking using ANFIS. *Renewable and Sustainable Energy Reviews*, 33, 602–612. doi:10.1016/j.rser.2014.02.014
- Kilic, E., Dolen, M., Koku, A., Çalıřkan, H., Balkan, T., (2012). Accurate pressure prediction of a servo-valve controlled hydraulic system. *Mechatronics*. 22. 997–1014. 10.1016/j.mechatronics.2012.08.001.
- Ljung, L., (2017). “System Identification Toolbox User’s Guide”, Disponível em: <http://www.mathworks.com>
- LJUNG, L., GLAD, T. “Modeling of dynamic systems”, 1ª ed., Prentice Hall International, United Kingdom, 1994.
- Mendonça, K. H. Sistema de controle Fuzzy na operação otimizada de redes setorizadas com bombeamento direto, 2016. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2016.
- Moreira, H. A. M., Gomes, H. P., Villanueva, J. M., 2019b. “Controle inteligente aplicado à um sistema de bombeamento de água”. 14º Simpósio Brasileiro de Automação Inteligente, 2019, Ouro Preto, MG
- Neto, J. T. C. Processamento de valores atípicos em redes elétricas inteligentes baseado em algoritmos Neuro - Fuzzy – João Pessoa, 2018.
- Nyquist, H. (1932). Regeneration Theory. *Bell System Technical Journal*, 11(1), 126–147. doi:10.1002/j.1538-7305.1932.tb02344.x.
- Oliveira, J. E. A., Serni, P. J. A., Ulson, J. A. C., Andreoli, A. L., Aguiar, P. R. A., Goedel, A. Modelagem de um Motor de Indução Trifásico Acionado com Tensões Desequilibradas por meio de Redes Neurais Artificiais, 2010.
- Oliveira, J. K. C. Lógica fuzzy aplicada na otimização operacional de rede setorizada de distribuição de água. 2017. 147f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2017.
- Pillonetto, G., Aravkin, A., Gedon, D., Ljung, L., Ribeiro, A. H., e Schön, T. B. (2023). Deep networks for system identification: a survey. arXiv preprint arXiv:2301.12832. DOI: <https://doi.org/10.48550/arXiv.2301.12832>
- Rossi, M., & Renzi, M. (2018). A general methodology for performance prediction of pumps-as-turbines using Artificial Neural Networks. *Renewable Energy*, 128, 265–274. doi:10.1016/j.renene.2018.05.060.
- Salvino, L. R. Eficiência energética em sistemas pressurizados de distribuição de água com o uso de redes neurais artificiais, 2016. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2016.
- Shabaan, S., Abu El-Sebah, M. I., & Bekhit, P. (2018). Maximum power point tracking for photovoltaic solar pump based on ANFIS tuning system. *Journal of Electrical Systems and Information Technology*, 5(1), 11–22. doi:10.1016/j.jesit.2018.02.002.
- Sun, W., Hu, P., Lei, F., Zhu, N., & Jiang, Z. (2015). Case study of performance evaluation of ground source heat pump system based on ANN and ANFIS models. *Applied Thermal Engineering*, 87, 586–594. doi:10.1016/j.applthermaleng.2015.04.082.
- Walia, N., Singh, H., Sharma, A., 2015. ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey. *International Journal of Computer Applications*. 123. 32-38. 10.5120/ijca2015905635.
- V. Vodovozov, I. Bakman, Z. Raud and T. Lehtla, "High-efficiency predictive control of pumping," 2016 15th Biennial Baltic Electronics Conference (BEC), Tallinn, Estonia, 2016, pp. 203-206, doi: 10.1109/BEC.2016.7743764.
- Zhang, Z., Kusiak, A., Zeng, Y., & Wei, X. (2016). Modeling and optimization of a wastewater pumping system with data-mining methods. *Applied Energy*, 164, 303–311. doi:10.1016/j.apenergy.2015.11.061.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.