

<http://dx.doi.org/10.48005/2237-3713rta2022v11n3p8295>

Mapeamento tecnológico da aplicação de redes neurais para eficiência energética de sistemas de bombeamento*

Technological mapping of the application of neural networks for energy efficiency of pumping systems

Ákilas Girão Modesto

Universidade Federal Fluminense - UFF

akilasgirao@id.uff.br

Flavio da Costa Almeida

Universidade Federal Fluminense - UFF

flavio_almeida@id.uff.br

Wanderson da Silva Corrêa

Universidade Federal Fluminense - UFF

wscorrea@id.uff.br

Márcio Zamboti Fortes

Universidade Federal Fluminense - UFF

mzamboti@id.uff.br

RESUMO ESTRUTURADO

Sistemas inteligentes para eficiência energética de bombas industriais vêm ganhando espaço nos últimos anos. Empresas têm desenvolvido redes neurais para monitorar e intervir no desempenho dos mais variados sistemas de bombeamento. O presente trabalho discute uma fundamentação teórica apresentando conceitos relacionados a sistemas de bombeamento e uso de redes neurais para economia de energia. O item de sistemas de bombeamento aborda as características das curvas de desempenho de bombas e conceitos relacionados a inversores de frequência. Verificou-se a importância da utilização deste equipamento, pois tem sido um dos mecanismos mais importantes para o controle da velocidade operacional das bombas. Por fim, apresenta-se o capítulo sobre redes neurais. Inicialmente, alguns conceitos foram mencionados e, posteriormente, destaca-se um modelo de rede neural recorrente. Os resultados da aplicação foram abordados e enfatizaram a importância do uso de redes neurais para economia de energia nos sistemas de bombeamento.

Palavras-chave: Redes Neurais, Eficiência Energética, Bombeamento.

STRUCTURED ABSTRACT

Intelligent systems for the energy efficiency of industrial pumps have been gaining ground in recent years. Companies have developed neural networks to monitor and intervene in the performance of the most varied pumping systems. The present work discussed a theoretical foundation presenting concepts related to pumping systems and the use of neural networks for

* Received 13 June 2022; accepted in 21 August 2022; published online 08 February 2023.

energy savings. The pumping systems chapter discussed the characteristics of pump performance curves. Concepts related to frequency inverters were also introduced in this chapter. The importance of using this equipment was verified, as it has been one of the most important mechanisms for controlling the operational speed of pumps. Finally, the chapter on neural networks was presented. Initially, some concepts were mentioned and a recurrent neural network model was presented later. The application results were discussed and emphasized the importance of using neural networks to save energy in these systems.

Keywords: Neural Networks, Energy Efficiency, Pumping

1. INTRODUÇÃO

A necessidade de realizar um controle mais inteligente na atuação de bombas que realizam movimentações de variados fluidos em indústrias, prédios comerciais ou residenciais têm impulsionado a pesquisa e o desenvolvimento em tecnologias que possam proporcionar o melhor rendimento possível para esses sistemas. O operador, ou pessoa responsável pelo acionamento desses equipamentos, mesmo bem treinado e qualificado, está sujeito a cometer erros que podem resultar em falhas no controle do processo. Assim, nos dias atuais, para a garantia de uma operação com maior confiabilidade e padronização, busca-se a aplicação de sistemas automáticos de controle para atendimento às demandas e aplicações que são necessárias [1].

Em relação a sistemas de bombeamentos que utilizam água industrial, por exemplo, o controle inteligente para monitoramento da pressão é uma das principais opções para aumentar a eficiência da distribuição, resultando positivamente na vida útil dos equipamentos envolvidos no processo e, conseqüentemente, na redução dos custos relativos à operação e manutenção, na redução das interrupções no abastecimento e vazamentos e, por fim, no aumento da credibilidade das empresas fornecedoras com os consumidores [2]. O bombeamento com água utilizando tecnologia de Internet das Coisas - IoT, como observado em [3], também é uma opção quando associado às energias renováveis em busca de maior eficiência.

A utilização de controle inteligente em sistemas de bombeamento em grandes indústrias também tem levado a resultados de ganhos de eficiência em equipamentos e acessórios de bombeamento. Em [4], por exemplo, observa-se a viabilidade de se desenvolver um sistema de reconhecimento de falhas, utilizando controles inteligentes, em sistemas de bombeio de petróleo.

Assim, os sistemas de bombeamento são responsáveis por quase 20% da energia mundial usada por eletricidade no funcionamento de motores e em torno de 25% a 50% do uso total de energia elétrica em instalações industriais [4]. Muitas iniciativas vêm sendo adotadas com foco na eficiência energética destes sistemas. Portanto, uma destas iniciativas é o controle mais inteligente para sistemas de bombeamento, gerando ganhos de economia de energia.

Alguns autores como apresentado em [5] têm mostrado em suas pesquisas que a alternativa mais eficiente para o controle de vazão e pressão em sistemas de bombeamento é o uso de inversores de frequência em conjuntos motobomba.

Diversos artigos tratam da aplicação de variadores de frequência como forma de obter sistemas com maior eficiência energética. Um sistema com cinco bombas paralelas, por exemplo, é investigado, conforme apresentado em [6]. O consumo de energia é comparado para

casos diferentes (um variador de frequência ou cinco variadores de frequência separados para cada bomba). No caso da aplicação de acionamentos de velocidade variável para cada bomba, o acionamento obtém redução do consumo de energia da rede em torno de 2,5%. Já a abordagem debatida em [7], o consumo de energia de três bombas é comparado ao variar o número de variadores de frequência, gerando resultados operacionais de alta eficiência e menor consumo de energia no sistema.

Com os avanços tecnológicos, a Rede Neural Artificial (RNA) surgiu como uma alternativa ao controle automático de sistemas de bombeamento onde diversas variáveis podem ser controladas. Esses avanços surgiram com a necessidade, por exemplo, de encontrar soluções tecnológicas de acesso à informação, como abordado por [8], ou buscar mais economia de energia através de um melhor acompanhamento e controle das variáveis do sistema, como será abordado nesse trabalho.

As redes neurais artificiais (RNA) imitam o processo de aprendizagem humana e podem lidar com problemas altamente complexos. Essa técnica é aplicada para o reconhecimento de padrões, não requer uma compreensão prévia do processo e/ou fenômeno modelado e possui a capacidade de aprender e “agir” perante as mais adversas situações, bem como adquirir conhecimento por meio da “experiência” e da observação. As RNAs também são altamente adequadas para aplicações na área de sistemas de processo, pois contemplam parâmetros de variáveis e sistemas que sofrem influência do tempo.

O objetivo deste trabalho é avaliar a aplicação de uma RNA para o controle de sistema de bombas visando a eficiência energética. Para tanto foi realizada uma revisão bibliográfica abordando os principais temas envolvendo a utilização de redes neurais em sistemas de bombeamentos. Buscou-se nesse trabalho, entender melhor os conceitos relativos a essa temática, além de apresentar um modelo de rede neural que atendesse a esses sistemas focando neste estudo bombas centrífugas.

2. METODOLOGIA

A metodologia utilizada neste trabalho foi a descrição dos conceitos e fenômenos relacionados ao tema de utilização das redes neurais como forma de eficiência energética de sistemas de bombeamento. Foi dada ênfase na apresentação de curvas características e inversores de frequência nestes sistemas. Uma rede neural também foi destacada, utilizando regressão linear e dados de séries temporais de pressão, vazão e potência. Ao final foi demonstrado o gráfico de valores previstos pelos valores de acionamento de inversores de frequência que seriam ótimos comparando-os aos valores encontrados pela rede neural.

A pesquisa bibliográfica foi realizada utilizando a base de dados do google acadêmico. Os filtros inseridos durante a pesquisa foram os citados na sequência: sistemas de bombeamento, rede neural e eficiência energética. Em algumas situações foram utilizadas as três palavras chaves ao mesmo tempo com o auxílio do operador booleano “AND”.

Diversos trabalhos apareceram como resultado da pesquisa e alguns destes foram estudados e avaliados, como artigos científicos, dissertações e teses. Algumas referências foram lidas parcialmente e, na sequência, verificadas a contribuição das informações presentes em seu conteúdo. O capítulo de referências deste trabalho condensou os principais trabalhos destacados e utilizados neste estudo.

3. SISTEMAS DE BOMBEAMENTO

3.1 Curvas Características

O desempenho das bombas centrífugas é representado por curvas características fornecidas pelos fabricantes. Elas traduzem o desempenho esperado de cada bomba. Existem 3 curvas características principais:

- Curva: Altura Manométrica x Vazão
- Curva: Potência x Vazão
- Curva: Rendimento x Vazão

A Figura 1 apresenta a curva altura manométrica x vazão que representa a relação entre a vazão que a bomba é capaz de fornecer e a altura manométrica total a qual essa vazão pode ser fornecida. Pode-se observar que a altura manométrica total cai gradualmente com o aumento da vazão.




Fig. 1 Curva Altura x Vazão

Quando uma bomba é instalada em um sistema, a interação pode ser ilustrada graficamente sobrepondo as curvas da bomba e do sistema. O funcionamento sempre será o ponto onde as duas curvas se cruzam, como observado na figura 2:

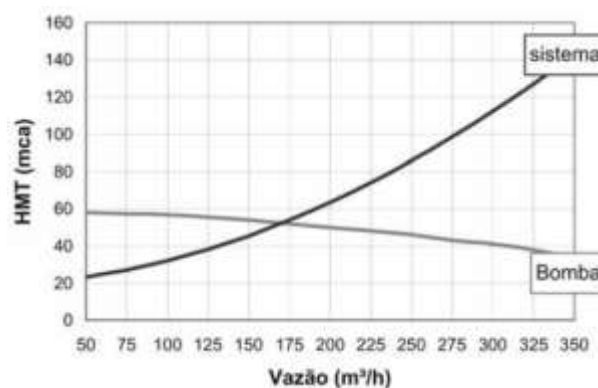


Fig. 2 Curvas do Sistema e da Bomba

Se a curva do sistema real for diferente daquela calculada, a bomba irá operar com uma vazão e altura manométrica diferente do esperado. O aumento da resistência do sistema poderá

reduzir a vazão a zero mas com uma pressão máxima limitada. Essa condição só é aceitável por um curto período sem causar problemas.

A Figura 3 representa a relação entre a vazão e a potência necessária. A potência expressa no gráfico representa a potência hidráulica absorvida pela bomba, isto é, a potência que o motor deve fornecer ao eixo da bomba.




Fig. 3 Curva Vazão x Potência

Por último, observa-se a figura 4 que representa a curva de rendimento pela vazão.




Fig. 4 Curva Vazão x Rendimento

3.2 Leis de Similaridade

As Leis de Similaridade interessam o estudo de eficiência das bombas centrífugas, elas refletem a variação das características da bomba (vazão, altura manométrica e potência) quando outras grandezas variam (rotação, diâmetro do rotor, etc.).

Especificamente as leis relacionadas a variação da rotação são as mais importantes pois permitem prever o comportamento da bomba com a aplicação de variadores de velocidade.

$$\frac{Q_1}{Q_2} = \frac{n_1}{n_2} \quad \text{Relação vazão x rotação} \quad (1)$$

$$\frac{H_1}{H_2} = \left(\frac{n_1}{n_2}\right)^2 \quad \text{Relação altura manométrica x rotação} \quad (2)$$

$$\frac{Pot_1}{Pot_2} = \left(\frac{n_1}{n_2}\right)^3 \quad \text{Relação potência x rotação} \quad (3)$$

Pode-se observar a relação diretamente proporcional entre a rotação e vazão, diretamente quadrática entre a rotação e a altura manométrica e diretamente cúbica entre a rotação e a potência.

3.3 Variador de Velocidade

A adoção de inversores de frequência é o mais importante mecanismo para o controle operacional de bombas. Estes têm por finalidade regular a velocidade de rotação das bombas por meio da variação da frequência e tensão de alimentação dos motores elétricos [9].

O controle por inversores é uma tecnologia necessária em sistemas de bombeamento, visto que o controle manual, primeira forma de controle utilizada pelo homem, ainda está presente em muitos processos e apresenta a necessidade de um operador humano com conhecimento do processo, assim como do sistema. Esse operador precisa possuir larga experiência e habilidade a fim de evitar acidentes e conseguir obter o máximo rendimento energético dos equipamentos e, por conseguinte, do processo como um todo [5].

Os inversores de frequência evoluíram muito, o desenvolvimento de dispositivos eletrônicos tornou possível o controle eficiente de velocidade de rotação por meio da variação da frequência e tensão da alimentação elétrica do sistema.

A utilização de conversores de frequência permite variar a velocidade de rotação do motor, mantendo a operação da bomba em níveis mínimos de potência, porém suficientes para o pleno atendimento das demandas, garantindo, assim, o controle piezométrico da rede, além da economia de energia, aumento da confiabilidade do sistema e prolongando a vida útil da estação elevatória como reportado em [10].

A equação 4 representa a relação entre a velocidade de rotação do eixo de um motor de indução trifásico e a frequência de acionamento do motor:

$$\eta_R = \frac{120 \times f}{p}(1-s) \quad (4)$$

Observa-se que η_R é a velocidade de rotação do eixo do motor, em rpm; f é a frequência de acionamento do motor, em Hz; p é o número de polos do motor; e s é o escorregamento do motor assíncrono.

De acordo com [5], a utilização de variadores de frequência ocasiona uma redução da potência dos motores possibilitando uma economia de energia de 30 a 50%.

A Figura 5 mostra o exemplo de um conjunto motobomba em operação com a atuação de uma válvula de manobra e de um inversor de frequência para o controle de vazão, apresentado por [11]. Ressalte-se que a operação com o estrangulamento da válvula de manobra exige uma altura manométrica maior. A diferença (destaque em amarelo) pode ser vista como a energia desperdiçada no processo.

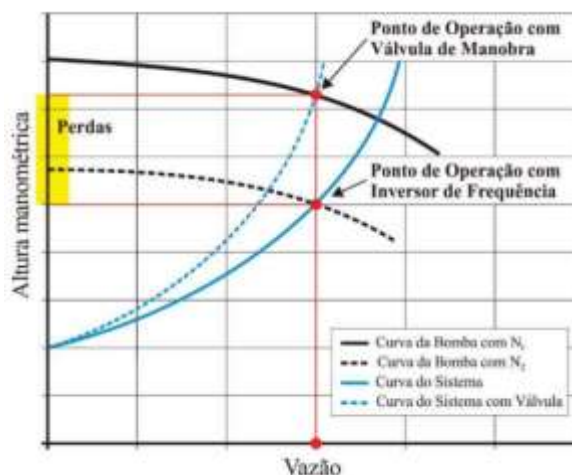


Fig. 5 Atuação de Válvula e Inversor de Frequência

Deve-se sempre verificar o sistema para a aplicação de variadores de velocidade para o controle de bombas a qual ela foi projetada, pois as relações quadráticas e cúbicas com a altura manométrica e a potência, conforme as Leis de Similaridade, proporcionarão variações pequenas na velocidade e poderão refletir alterações significativas nestes parâmetros.

4. REDES NEURAIS

RNA são modelos computacionais fundamentados no funcionamento do sistema nervoso dos seres vivos. As RNA imitam o processo de aprendizagem humana e podem lidar com problemas altamente complexos, mesmo que os dados avaliados sejam imprecisos e estejam relacionados por funções não lineares [10]. A rede neural é formada por um conjunto de unidades processadoras (neurônios artificiais), e geralmente é arquitetada em três camadas [12].

Uma rede neural é um processador, paralelo e distribuído, constituído de unidades de processamento simples que têm a propensão natural para armazenar conhecimentos experimentais e torna-os disponíveis para uso que se assemelha ao cérebro em dois aspectos:

- O conhecimento é adquirido pela rede neural por meio de dados do ambiente, num processo de aprendizagem.

- As conexões entre os neurônios, conhecidos como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido [13].

A literatura aborda que é possível implantar um sistema de controle utilizando Redes Neurais com bombas em paralelo, acionadas por conversores de frequência, para analisar seu comportamento em uma bancada experimental totalmente instrumentalizada, simulando o bombeamento em configurações de demandas variáveis. Logo, o monitoramento minucioso dos parâmetros hidráulicos característicos de uma rede de abastecimento, tais como: pressão, vazão e potência.[14]

A ideia deste trabalho foi utilizar uma rede neural artificial RNA recorrente, pois esta é uma classe de RNA em que as conexões entre os nós formam um gráfico direcionado, ou não direcionado, ao longo de uma sequência temporal. Isso permite que ele realize a exibição de

um comportamento dinâmico temporal [15]. A ilustração de uma rede neural recorrente pode ser visualizada na figura 6.




Fig. 6 Rede Neural Recorrente

Um nó é modelado conforme o comportamento de um neurônio humano. Os nós são ativados quando há estímulos ou entradas suficientes. Essa ativação se espalha através da rede, criando uma resposta ao estímulo. As conexões entre esses neurônios artificiais agem como sinapses simples, fazendo os sinais sejam transmitidos de um para o outro. Há sinalização entre camadas conforme eles viajam da primeira entrada até a última do resultado. Estas também são processadas ao longo do caminho.

Quando confrontados com uma requisição ou problema para resolver, os neurônios executam cálculos matemáticos para decidir se há informações suficientes a serem enviadas para o próximo neurônio. Resumidamente, eles leem todos os dados e decidem onde as relações mais fortes estão. No tipo mais simples de rede, as entradas de dados recebidas são somadas e, se a soma for maior que um valor limítrofe, o neurônio “dispara” e ativa os neurônios conectados a ele. Conforme o número de camadas ocultas dentro de uma rede neural aumenta, redes neurais profundas são formadas.

Arquiteturas de *deep learning* levam redes neurais simples a outro nível. Usando essas camadas, cientistas de dados podem construir suas próprias redes de *deep learning* que possibilitam o *machine learning*, no qual o computador pode ser treinado para emular tarefas humanas com precisão, como reconhecer fala, identificar imagens ou realizar previsões.

Igualmente, o computador pode aprender por si só a reconhecer padrões em muitas camadas de processamento. Dados são inseridos em uma rede neural através da camada de entrada, que se comunica com as camadas ocultas. O processamento acontece nessas camadas através de um sistema de conexões ponderadas.

Os nós nas camadas ocultas combinam os dados da camada de entrada com um conjunto de coeficientes e atribui diferentes pesos para as entradas. Os resultados dessas entradas avaliadas são, então, somados. A soma passa pela função de ativação de um nó, que determina a extensão em que um sinal deve progredir na rede para afetar o resultado final. Finalmente, as camadas ocultas ligam-se a camada de saída – de onde os resultados são obtidos.

A técnica estatística de recorrência é usada para estudar a relação entre uma variável dependente e várias variáveis independentes explicativas; ela também é bastante aplicada pela comunidade científica. Em Engenharia de Avaliações geralmente trabalha-se com Modelos de recorrência, tendo-se em vista a multiplicidade de fatores que interferem nos preços de um bem [16]. O Modelo Genérico Linear Geral é dado pela expressão da equação 5 apresentada em [17] quando aplicado a uma amostra de tamanho n .

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i, \quad i = 1, 2, \dots, n. \quad (5)$$

onde:

y_i = variável dependente ou explicada $i = 1, 2, \dots, n$, também chamada de resposta;

β_0 = intercepto ou termo independente de variável;

β_k = inclinação de Y em relação à variável X_k , mantendo constantes as variáveis X_1, X_2, \dots, X_{k-1}

ε_i = erro aleatório em Y, para a observação $i, i = 1, 2, \dots, n$.

A aplicação deste modelo requer que $\varepsilon_i \sim N(0, \sigma^2)$, ou seja, que os erros das observações i sejam Gaussianas, independentes, com média zero e variância constante.

A arquitetura de uma rede neural *Long Short Term Memory* - LSTM é uma arquitetura de rede neural recorrente (RNN) que “lembra” valores em intervalos arbitrários. A LSTM é bem adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. A insensibilidade relativa ao comprimento do gap dá uma vantagem à LSTM em relação a RNNs tradicionais (também chamadas “vanilla”), Modelos Ocultos de Markov (MOM) e outros métodos de aprendizado de sequências.

A estrutura de uma RNN é muito semelhante ao Modelo Oculto de Markov. No entanto, a principal diferença é como os parâmetros são calculados e construídos. Uma das vantagens da LSTM é a insensibilidade ao comprimento do gap. RNN e MOM dependem do estado oculto antes da emissão / sequência. Se quisermos prever a sequência após 1.000 intervalos em vez de 10, o modelo esquece o ponto de partida até então. Mas um modelo LSTM é capaz de “lembrar” por conta de sua estrutura de células, o diferencial da arquitetura LSTM.

A LSTM possui uma estrutura em cadeia que contém quatro redes neurais e diferentes blocos de memória chamados células. A informação é retida pelas células e as manipulações de memória são feitas pelos portões (*gates*). Existem três portões:

Forget Gate: As informações que não são mais úteis no estado da célula são removidas com o *forget gate*. Duas entradas: x_t (entrada no momento específico) e h_{t-1} (saída de célula anterior) são alimentadas ao *gate* e multiplicadas por matrizes de peso, seguidas pela adição do *bias*. O resultante é passado por uma função de ativação que fornece uma saída binária. Se para um determinado estado de célula a saída for 0, a informação é esquecida e para a saída 1, a informação é retida para uso futuro.

Input Gate: A adição de informações úteis ao estado da célula é feita pelo *input gate*. Primeiro, a informação é regulada usando a função sigmoide que filtra os valores a serem lembrados de forma similar ao *forget gate* usando as entradas h_{t-1} e x_t . Então, um vetor é criado usando a função *tanh* que dá saída de -1 a +1, que contém todos os valores possíveis de

h_{t-1} e x_t . Os valores do vetor e os valores regulados são multiplicados para obter as informações úteis

Output Gate: A tarefa de extrair informações úteis do estado da célula atual para ser apresentadas como uma saída é feita pelo *output gate*. Primeiro, um vetor é gerado aplicando a função *tanh* na célula. Então, a informação é regulada usando a função sigmóide que filtra os valores a serem lembrados usando as entradas h_{t-1} e x_t . Os valores do vetor e os valores regulados são multiplicados para serem enviados como uma saída e entrada para a próxima célula.

A célula RNN recebe duas entradas, a saída do último estado oculto e a observação no tempo t . Além do estado oculto, não há informações sobre o passado para se lembrar. A memória de longo prazo é geralmente chamada de estado da célula. As setas em *loop* indicam a natureza recursiva da célula. Isso permite que as informações dos intervalos anteriores sejam armazenadas na célula LSTM.

O estado da célula é modificado pelo *forget gate* colocado abaixo do estado da célula e também ajustado pela porta de modulação de entrada. Da equação, o estado da célula anterior esquece, multiplica-se com a porta do esquecimento e adiciona novas informações através da saída das portas de entrada.

Com a utilização do Python 3.8 que é uma linguagem *Open-Source* de propósito geral, usado bastante em *data applied*, *machine learning*, desenvolvimento de web, torna-se possível o desenvolvimento de aplicativos, automação de *scripts*, na IDE do Spyder que é uma interface gráfica, semelhante ao Matlab, permitindo a utilização de Python num ambiente interativo, facilitando a edição de *scripts*, teste, *debugging* e visualização gráfica.

Uma rede neural profunda de regressão linear foi desenvolvida e irá utilizar dados de series temporais de pressão, vazão e potência. Como valores de teste, os dados coletados possuem um intervalo dividido em horas e coletam informações de alturas e posições diferentes das 3 entradas. Ao final será demonstrado o gráfico de valores previstos pelos valores de acionamento de inversoras que seriam ótimos x valores encontrados pela rede neural.

A rede neural terá três valores de entrada que se conectam a primeira camada oculta LSTM com cem neurônios, a próxima camada também LSTM terá cinquenta neurônios e a última camada oculta LSTM também terá cinquenta neurônios, ao fim uma camada de saída densa com um neurônio apenas.

A função de ativação escolhida foi a sigmoide para o funcionamento ideal da função, os dados foram processados e normalizados, os transformando em valores entre zero e um. A função erro será a de erro médio quadrático. Ela irá encontrar os erros das épocas para a retro propagação, o valor da taxa de aprendizagem será atualizado automaticamente pelo próprio *script* enquanto ele executa as épocas da rede neural.

5. REDES NEURAIIS PARA CONTROLE DE BOMBAS

A melhoria do desempenho do sistema de bombeamento é muito importante para a economia de energia. Para aumentar a eficiência do sistema a aplicação de RNA tem como objetivo a otimização de variáveis do sistema (vazão, pressão, corrente, rendimento, etc.).

Em [1] implementou-se um algoritmo de rede neural artificial integrado ao sistema de supervisão de um processo de bombeamento industrial, visando o aumento da eficiência

energética. A rede neural artificial implementada auxiliou o controle industrial tradicional, do tipo PI, tornando o sistema mais eficiente energeticamente.

Em [2] apresenta-se a utilização de redes neurais para o controle de pressão de redes de distribuição de água. A rede neural foi responsável pela manutenção da altura manométrica do sistema de bombeamento em um valor ótimo, eliminando qualquer excesso de pressão no ponto crítico do sistema.

Em [18] desenvolveram-se 3 RNA usando os dados de velocidade do motor, potência ativa do motor e a corrente do estator. De acordo com os resultados, a utilização da RNA forneceu uma economia de energia da ordem de 33%.

Em [15] implementou-se um sistema de controle direto via Redes Neurais Artificiais, com arquitetura recorrente, para automatizar uma bancada experimental que simula um sistema de abastecimento com bombeamento direto na rede de distribuição.

6. RESULTADOS

Utilizando-se para os testes um notebook Avell Gaming Series, SO Windows 10, com 16 Gb de Memória ram, Hd SSD de 1 tera, Processador i7 da sétima geração e placa de vídeo 1060 TI de 4 Gb a 360 Ghz.

Inicialmente foram realizados testes com um dos métodos de persistência para comparação de resultados. Para todos os casos apresentados o número de neurônios nas camadas intermediárias indicado faz parte da configuração que apresentou os melhores resultados após diversas simulações.

Para se definir a melhor configuração utilizou-se o método de tentativa e erro variando o número de neurônios para valores superiores e inferiores do valor inicial. Na maioria dos casos, o número de 10.000 épocas foi suficiente para que o erro nos testes ficasse praticamente constante. E no caso da rede com 144 saídas, 5.000 épocas já foram suficientes para atingir este ponto, não sendo necessário continuar até 10.000 épocas para não aumentar o tempo de processamento.

O tempo de treinamento dos casos apresentados variou de 30 minutos à 1 hora. No caso da rede de 144 saídas, o tempo de treinamento da rede ultrapassou às 4 horas. O treinamento para o caso em que se apresenta 24 redes neurais também foi longo, durando em torno de 12 horas, mas isso se deve ao treinamento sequencial das redes propostas, problema que facilmente seria resolvido por processamento em paralelo, visto que as redes possuem dados que não dependem uma da outra.

Inicialmente, para efeito de comparação, foi realizada a previsão de 144 passos à frente (24 horas) aplicando o método de persistência da seguinte maneira:

Passo 1: calcular a distância euclidiana entre os 144 pontos da hora anterior à hora que se deseja prever com os 144 pontos das horas que estão no arquivo de treinamento.

Passo 2: ordenar os valores da distância euclidiana e selecionar o de menor valor.

Passo 3: definir como a previsão desejada os 144 pontos da hora seguinte ao momento selecionado no passo 2.

O erro médio obtido nos 36 casos de testes foi de 58.90 %. A Figura 7 apresenta o resultado da previsão de 144 passos à frente para 2 casos de teste:

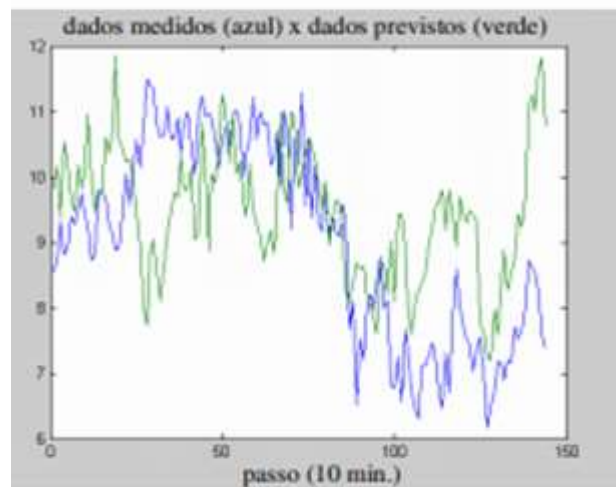


Fig. 7 Dados com passo 10min

Por último, fez-se uma simulação da rede de 50 saídas na base de horas cheias combinada com a saída da rede com 6 saídas na base de 10 minutos, que foi a que apresentou os melhores resultados para a previsão de 50 horas à frente.

Executou-se esta combinação seguindo os passos:

- Executar a rede com a base de dados somente com horas cheias utilizando-se os dados de vazão, visto que os resultados apresentados mostram que, para este modelo, a previsão com dados de vazão possui melhores resultados do que quando não se utiliza os dados de vazão.

- Executar a rede de 50 saídas, sem utilizar os dados de vazão, uma vez que este foi o modelo que apresentou melhores resultados, e realizar a simulação desta rede 50 vezes, uma para cada hora. A cada simulação da rede de 50 saídas, substituir a velocidade prevista para a hora cheia com a média dos valores previstos nos dois modelos utilizados, para se evitar ocorrência de picos decorrente da falta de continuidade dos modelos. Nesta combinação de modelos, o erro médio obtido nos 36 casos de testes foi de 0,11%.

A rede de 50 passos com vazão foi a que apresentou melhores resultados quando se trabalhou com redes isoladas. Logo, na combinação com a rede de 24 saídas na base de horas cheias era esperado que se tivesse o menor índice de erro médio, visto que esta combinação de modelos já havia apresentado melhorias nos resultados.

Foram realizadas simulações com a mesma combinação utilizando-se dados de vazão nos dois modelos, obtendo-se um erro médio para os 50 casos de testes de 0,21 % e sem utilizar os dados de vazão em nenhum dos dois modelos e obtendo-se um erro médio nos 50 casos de testes de 1,26%. Estes resultados já eram esperados que fossem maiores do que a combinação proposta anteriormente visto que os modelos isolados apresentaram melhores resultados para uso de inversores na rede com 24 saídas na base de horas cheias e sem utilizar inversores para a rede de 6 saídas na base de 10 minutos.




Fig. 8 Dados medidos x previstos em horas

7. CONCLUSÃO

O presente trabalho discorreu sobre temas importantes relacionados à utilização de redes neurais em sistemas de bombeamento com a finalidade de abordar economia de energia para estes equipamentos. Observou-se pelos trabalhos estudados que a utilização de redes neurais proporcionou otimização no controle das variáveis dos sistemas estudados, como por exemplo, os resultados vistos nos trabalhos citados no item V. Utilizando Redes Neurais LSTM também foi possível realizar a estimativa de acionamento de um inversor de frequência. Os resultados mostraram através das simulações os benefícios da utilização de sistemas inteligentes. Outras abordagens podem ser desenvolvidas nesta linha de estudos como, por exemplo, modelagem de uma *Boltzman Machine* trabalhando com técnicas de controle e sensores que colem dados da natureza para estimar o desempenho e consumo ótimo de energia em veículos autônomos. Portanto, uma economia significativa do consumo de energia elétrica poderá ser obtida em sistemas de bombeamento quando o sistema controlado for auxiliado por uma rede neural artificial.

8. REFERÊNCIAS

- [1] R. R. B. Aquino et al. Eficiência Energética no Controle e Automação de Processos Industriais Utilizando Redes Neurais Artificiais. *Eletrônica de Potência*, vol. 14, no. 2, pp. 117-124, 2009. doi: 10.18618/REP.2009.2.117124
- [2] G. A. Moura et al. Rede Neural Adaptativa Aplicada ao Controle de Pressão em Sistemas de Distribuição de Água. Congresso Associação Brasileira de Energia Sanitária e Ambiental – ABES FENASAN 2017.
- [3] I. M. Dupont et al. Internet of Things Data acquisition system applied to photovoltaic water pumping. *IEEE Latin America Transactions*, v. 16, n. 10, p. 2547-2560, 2018. doi:10.1109/TLA.2018.8795134.
- [4] M. A. D. Bezerra. “Aplicação de redes neurais artificiais no reconhecimento de padrões de cartas dinâmométricas de fundo em sistemas de bombeio mecânico de petróleo”. Dissertação (Mestrado) Escola Politécnica e Instituto de Matemática, Universidade Federal da Bahia, Salvador, 2010.

- [5] EUROPUMP; HYDRAULIC INSTITUTE. Variable speed pumping: A guide to successful applications. 1. Ed. Bodmin, Cornwall: Elsevier, 2004. 170p
- [6] Ahmed, A.; Moharam, B.; Rashad, E. Power Saving of Multi Pump-Motor Systems Using Variable Speed Drives. In Proceedings of the 2018 Twentieth International Middle East Power Systems Conference (MEPCON), Cairo, Egypt, 18–20 December 2018. doi:10.1109/MEPCON.2018.8635157.
- [7] Luo, Y.; Xiong, Z.; Sun, H.; Guo, Y. Research on energy-saving operation control model of the multi-type configuration centrifugal pump system with single invert. *Advances in Mechanical Engineering*. 2017, 9, 1–10. doi:10.1177/1687814017707650.
- [8] E. S. Paiva, A. B. Paim and N. F. F. Ebecken. Convolutional Neural Networks and Long Short-Term Memory Networks for Textual Classification of Information Access Requests. *IEEE Latin America Transactions*, v. 19, n. 5, p. 826-833, 2021. doi:10.1109/TLA.2021.9448317.
- [9] E. G. Barros Filho et al. Aplicação de Redes Neurais na Operação de Sistemas de Bombeamento. XVII Simpósio Luso-Brasileiro de Engenharia Sanitária e Ambiental. Florianópolis. 2016.
- [10] E. G. Barros Filho, “Sistema Inteligente para o Controle de Pressão de Redes de Distribuição de Água Abastecidas por Bombas Associadas em Paralelo”, Tese de doutorado, Dept. Pós-Graduação em Engenharia Mecânica, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, 2016
- [11] S. T. M. Bezerra; S. A. Silva; H. P. Gomes; M. M. Salvino, Energy savings in pumping systems: application of a fuzzy system. *Ciência & Engenharia*, v. 24, n. 1, p. 71-78, jan.-jun. 2015. doi: 10.14393/19834071.2015.22536.
- [12] L. R. Salvino et al. Capítulo 5. Técnicas de controle inteligente aplicadas em sistemas de bombeamento direto. *Los Servicios de Agua y Drenaje Com una Visión Integral*, p. 287. 2015
- [13] L.F.A. Cordeiro, “Eficiência Energética no Controle Inteligente de Sistemas de Bombeamento”, dissertação de mestrado, Departamento de Pós-Graduação em Eng. Elétrica, Universidade Federal de Pernambuco, Recife, PE, Brasil, 2008.
- [14] E. G. Barros Filho et al. Capítulo 6. Aplicação de sistema de controle utilizando redes neurais para operação de bombas em paralelo. *Los Servicios de Agua y Drenaje Com una Visión Integral*, p. 299. 2015
- [15] L. R. Salvino et al. Bombeamento direto Automatizado Através de Redes Neurais Artificiais Visando o Aumento da Eficiência Energética. Congresso Associação Brasileira de Energia Sanitária e Ambiental - ABES FENASAN 2017.
- [16] C. M. Bichop, “Pattern Recognition and Machine Learning” First edition, mar 2006.
- [17] H. Simon, “Neural Networks and Learning machines” Third edition, jul 2008.
- [18] S.O. Burian, O.I. Kiselychnyk, M.V. Pushkar, V.S. Reshetnik and H.Y. Zemlianukhina, "Energy-Efficient Control of Pump Units Based on Neural-Network Parameter Observer", *Technical Electrodynamics*, no. 1, pp. 71-77, 2020. doi: 10.15407/techned2020.01.071