

ESTIMATIVA DE VAZÃO DE UM SISTEMA DE BOMBEAMENTO FOTOVOLTAICO USANDO REDES NEURAS ARTIFICIAIS

Leandro de Oliveira¹; Andressa Rustick²; José Airton Azevedo dos Santos³

Resumo

O bombeamento de água é uma das atividades mais difundidas do emprego de energia solar fotovoltaica. Com base neste contexto, este trabalho tem como objetivo implementar e analisar modelos, baseados em redes neurais artificiais, para estimar a vazão de um sistema de bombeamento fotovoltaico, localizado na região oeste paranaense. A base de dados apresenta um histórico de um ano, contendo as seguintes variáveis: hora, temperatura, irradiação solar e vazão da bomba. Modelos, baseados na arquitetura *Multilayer Perception* (MLP), foram implementados por meio do *framework* Keras. Resultados obtidos, dos modelos de redes neurais, foram comparados por meio das métricas: R^2 (Coeficiente de Determinação), MSE (Erro Quadrático Médio) e RMSE (Raiz do Erro Quadrático Médio). Dados, de dois dias de cada estação do ano, foram utilizados para testar o modelo com melhor desempenho no conjunto de validação. Os resultados sugerem que o modelo, de rede neural artificial MLP, é adequado para prever a vazão do sistema de bombeamento fotovoltaico.

Palavras-chave: Energia solar; Rede MLP; Previsão.

Abstract

Pumping water is one of the most widespread activities in the use of photovoltaic solar energy. Based on this context, this work aims to implement and analyze models, based on artificial neural networks, to estimate the flow of a photovoltaic pumping system, located in the western region of Paraná. The database presents a one-year history, containing the following variables: time, temperature, solar irradiation and pump flow. Models, based on the Multilayer Perception (MLP) architecture, were implemented using the Keras framework. Results obtained from neural network models were compared using the following metrics: R^2 (Coefficient of Determination), MSE (Mean Squared Error) and RMSE (Root of Mean Squared Error). Data, from two days of each season of the year, were used to test the best performing model in the validation set. The results suggest that the MLP artificial neural network model is adequate to predict the flow of the photovoltaic pumping system.

Keywords: Energy; MLP network; Forecasting.

1 Introdução

A geração de energia, por meio de combustíveis fósseis, contribui para o efeito estufa, aquecimento global e para catástrofes climáticas. A energia solar, alternativa ao uso dos combustíveis fósseis, é uma energia abundante, não poluente e dispersa (JARDIM, 2007; ANTONELI; NEITZEL, 2016).

¹ Mestrando do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA) UTFPR. E-mail: leandrooliveira@alunos.utfpr.edu.br.

² Mestranda do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA) UTFPR. E-mail: andressarustick@hotmail.com.

³ Docente Permanente do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA) UTFPR. E-mail: airton@utfpr.edu.br; professorjairton@gmail.com.

A energia solar pode ser utilizada na geração de eletricidade, por meio de painéis fotovoltaicos, para iluminação e bombeamento de água. Segundo Moraes *et al.* (2020) “a água é essencial para sobrevivência humana, sem ela não existiria vida no planeta”. Sistemas de bombeamento fotovoltaico, devido a demanda por água pela população, são uma boa opção para áreas rurais e locais isolados (OYAMA, 2008; SILVA; BASCOPE, 2020).

Segundo Kolling (2001), a qualidade de vida da população depende da garantia do suprimento de água de boa qualidade. O suprimento de água de boa qualidade reduz a incidência de enfermidades associadas ao acesso inadequado da mesma. Proporcionando também redução do fluxo migratório, responsável pela superpopulação urbana.

As Redes Neurais Artificiais (RNAs) podem ser aplicadas em várias áreas do conhecimento. São sistemas paralelos formados pela interconexão de unidades de processamento simples, denominadas neurônios. As RNAs, utilizando um conjunto de exemplos, são capazes de generalizar, o conhecimento assimilado, para um conjunto de dados desconhecido. É uma técnica de modelagem que pode resolver muitos problemas complexos (HAYKIN, 2001; BRAGA *et al.*, 2007).

Neste contexto, este trabalho tem como objetivo implementar e analisar modelos, baseados em redes neurais artificiais, para estimar a vazão de um sistema de bombeamento fotovoltaico, localizado na região oeste paranaense. Segundo Haddad *et al.* (2015) a previsão, de vazão de um sistema de bombeamento fotovoltaico, é de grande importância para um sistema eficiente de demanda de água em áreas rurais e locais isolados.

O artigo é organizado da seguinte maneira. Na Seção 2 é apresentada a metodologia utilizada na previsão da vazão do sistema de bombeamento fotovoltaico. Na Seção 3 são apresentados os resultados obtidos e suas respectivas discussões. Comentários finais e conclusões, na Seção 4, finalizam o artigo.

2 Materiais e métodos

Nesta seção apresentam-se o sistema de bombeamento fotovoltaico, as redes neurais artificiais, as métricas utilizadas, bem como as etapas do trabalho.

2.1 Sistema de bombeamento

O sistema de bombeamento, devido a configuração do sistema, foi formado por dois módulos fotovoltaicos MSX56 ligados em série. Os módulos MSX56, do fabricante Solarex, possuem uma tensão padrão de 12V, corrente padrão de 3,35A e uma potência de 56 W (MICHELS, 2007).

Uma bomba, modelo SDS-D-228 do tipo diafragma (Fabricante SolarJack – (SUN PUMPS, 2023)), de trabalho submerso, com tensão próxima de 30Vcc foi alimentada pelo sistema fotovoltaico e bombeou água a uma altura de 20 metros, altura entre a cisterna e a caixa de água na qual foi instalada. Um medidor de vazão (Figura 1), do tipo turbina (Fabricante Lao), foi instalado para medir a vazão total do sistema de bombeamento (MICHELS, 2007; OLIVEIRA; SANTOS, 2022).

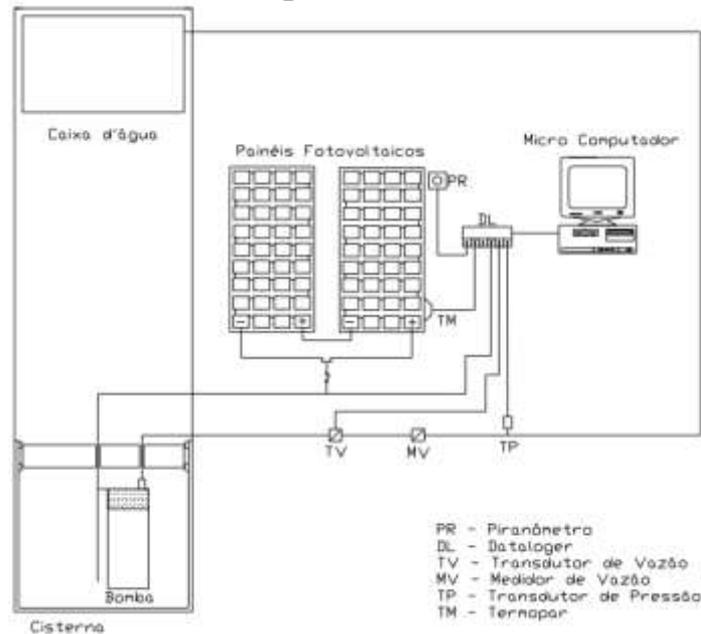
Figura 1 - Medidor e transdutor de vazão



Fonte: Michels (2007).

A aquisição dos dados foi realizada por meio de um sistema de aquisição da Campbell Scientific. O sistema de aquisição foi programado para realizar a leitura e armazenar, por minuto, os dados das componentes de irradiação global na mesma inclinação do painel, temperatura de operação do painel, tensão e corrente do sistema fotovoltaico. A temperatura, de operação do painel fotovoltaico, foi obtida de um termopar do tipo K, localizado na parte de trás do painel. Os valores de irradiação global foram obtidos por meio de um piranômetro Kipp & Zonen (MICHELS, 2007; OLIVEIRA; SANTOS, 2022). A Figura 2 indica o posicionamento de cada equipamento, tanto do conjunto fotovoltaico como do sistema de controle.

Figura 2 - Sistema de bombeamento de água

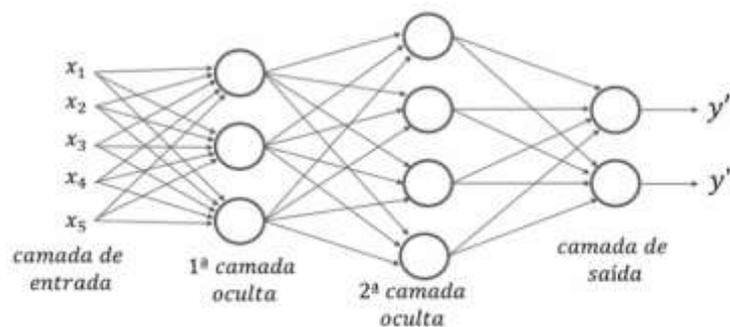


Fonte: Michels (2007).

2.2 Redes neurais

As redes MLPs, classificadas como redes do tipo *feedforward*, são utilizadas para resolver diversos tipos de problemas (SILVA, 2015). São constituídas por uma camada entrada, uma ou mais camadas escondidas e uma camada de saída (Figura 3). Nestas redes as saídas dos neurônios, de uma determinada camada, se conectam apenas às entradas dos neurônios da camada seguinte. Neste trabalho utiliza-se, para treinamento da rede, o algoritmo *backpropagation*. O *backpropagation* é um algoritmo muito utilizado para treinamento de redes neurais do tipo *feedforward*. As redes MLPs podem realizar tanto regressão quanto classificação (BASTIANI et al., 2018; PINHEIRO et al., 2020; OLIVEIRA; SANTOS, 2022).

Figura 3 - Arquitetura - Rede MLP



Fonte: Oliveira (2023).

2.3 Métricas

Os modelos, implementados neste trabalho, foram avaliados pelas seguintes métricas (SANTOS, 2021; SANTOS; CHAUKOSKI, 2021).

- Coeficiente de Determinação (R^2): Indica a qualidade do ajuste de um modelo a variável que se pretende explicar. O coeficiente de determinação varia entre 0 e 1, por vezes sendo expresso em percentagem. Quanto mais próximo de 1 melhor o ajuste.

- Erro Quadrático Médio (MSE): É uma forma de avaliar a diferença entre um estimador e o verdadeiro valor da quantidade estimada (Eq. 1). Valor perfeito – MSE=0.

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

- Raiz do Erro Quadrático Médio (RMSE): é a Raiz do erro quadrático médio da diferença entre a predição e o valor real (Eq. 2). Valor perfeito – RMSE=0.

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

Onde: y_i é o valor real do período i , \hat{y}_i é a previsão para o período i e n é o número de observações.

2.4 Etapas do trabalho

O trabalho foi dividido em três etapas: Coleta e análise dos dados, Modelagem e Teste (Quadro 1).

Quadro 1 - Descrição das etapas do trabalho

ETAPAS	DESCRIÇÃO
Coleta e análise dos dados	Nesta etapa os dados foram coletados e analisados por meio de uma análise exploratória. A análise exploratória ajuda a extrair informações importantes de um conjunto de dados.
Modelagem	Na etapa de modelagem foram implementados vários modelos de redes neurais MLP. Nesta etapa o modelo com melhor desempenho, no conjunto de validação, foi selecionado.
Teste	Nesta etapa o modelo foi testado com dados que não participaram do processo de treinamento e validação (dois dias de cada estação do ano).

Fonte: Elaborada pelos autores (2023).

2.5 Recursos

Para implementação do algoritmo foi utilizado o ambiente de desenvolvimento Jupyter Notebook. As bibliotecas de aprendizado de máquina: Scikit-learn, Pandas, Matplotlib e Keras foram também utilizadas. Os modelos foram executados por um notebook com o sistema Linux Ubuntu. O notebook conta com um processador Intel(R) Core(TM) i7-2670QM, 2,8GHz e 16GB de memória RAM.

3 Resultados e Discussões

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados de Temperatura (TP - °C), Irradiação (IR – W/m²) e Vazão (VZ – L/min) (Tabela 1).

Tabela 1 - Análise descritiva de dados

Parâmetro	TP	IR	VZ
Instâncias	18720	18720	18720
Média	33,2	576,5	3,03
Mínimo	5,42	0	0
Máximo	60,06	1095	5,21
Desvio Padrão	13,27	343	2,09
Coef. de Variação	39,96%	59%	68,50%

Fonte: Elaborada pelos autores (2023).

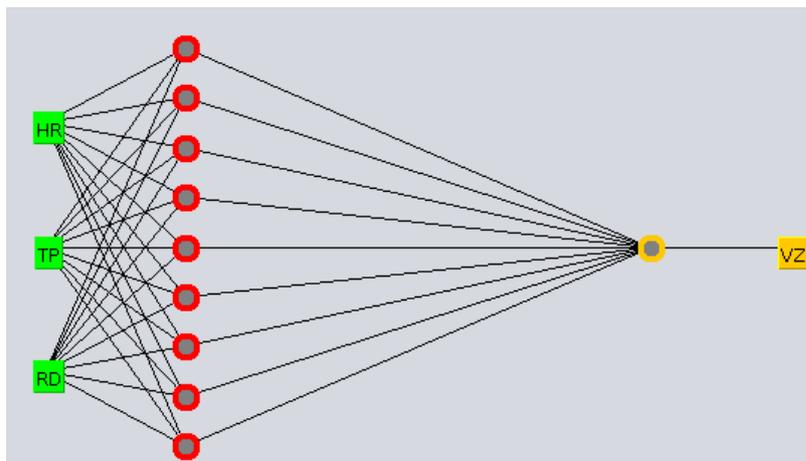
Pode-se notar, dos dados apresentados na Tabela 1, que o sistema, em estudo, apresenta uma temperatura média de 33,2^oC, uma irradiação média de 576,5W/m² e uma vazão média de 3,03L/min. Apresentando valores máximos para temperatura, irradiação e vazão de 60,06^oC, 1095W/m² e 5,21L/min. Observa-se também que os coeficientes de variação estão um pouco altos, indicando variabilidade nos dados.

3.1 Treinamento e validação

Neste trabalho, vários modelos de redes neurais MLP foram testados utilizando como indicadores de desempenho as métricas Coeficiente de Determinação (R²), Erro Quadrático Médio (MSE) e Raiz do Erro Quadrático Médio (RMSE). As redes neurais foram treinadas com 13104 amostras (70%) e validadas com 5618 amostras (30%). O melhor modelo utilizou o algoritmo de otimização Adam com os seguintes hiperparâmetros: *Hidden Layer Neurons* = 9; *Learning rate* = 0.01; *Batch* = 100; *Epochs* = 500 e *Activation Function* = Sigmoid.

A rede, utilizada neste trabalho (Figura 4), foi especificada como MLP 3:9:1 com três neurônios na camada de entrada (Hora – HR, Temperatura – TP e Irradiação – RD), nove neurônios na camada intermediária e um neurônio na camada de saída (Vazão – VZ).

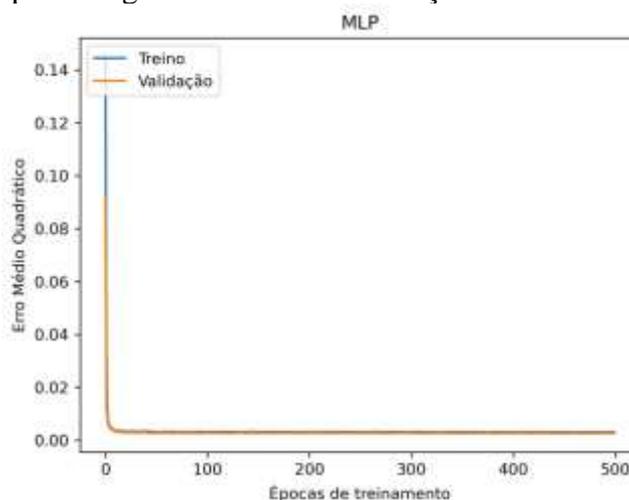
Figura 4 - Rede neural MLP



Fonte: Elaborada pelos autores (2023).

Na Figura 5 apresenta-se a curva de aprendizagem do modelo MLP 3:9:1. Pode-se observar, nesta figura, a boa estabilidade na convergência das curvas de Treino e Validação.

Figura 5 - Curvas de aprendizagem de Treino e Validação



Fonte: Elaborada pelos autores (2023).

Os resultados das métricas, para o conjunto de validação, são apresentados na Tabela 2.

Tabela 2 - Resultados - Métricas

Parâmetro	RNA
R^2	0,984
MSE	0,002
RMSE	0,05

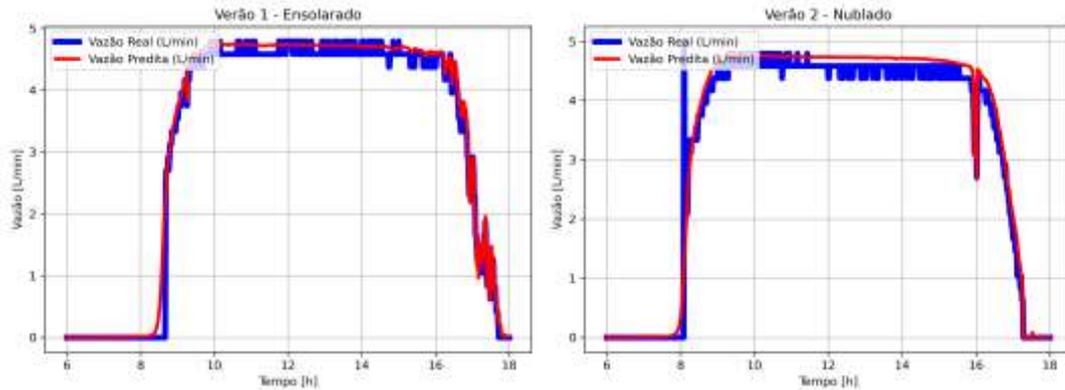
Fonte: Elaborada pelos autores (2023).

Observa-se que os resultados das métricas, mostrados na Tabela 2, apresentam baixos valores para os erros MSE e RMSE, apresentando também um valor de R^2 próximo de 1.

3.2 Testes

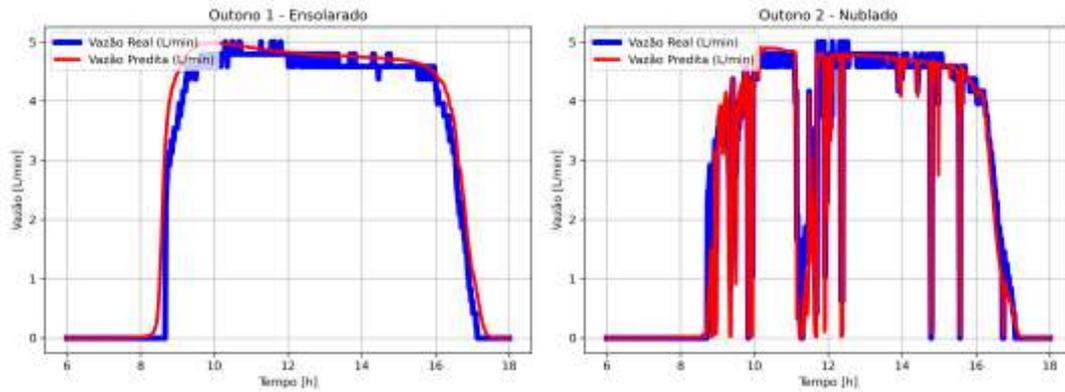
Para testar o modelo da RNA compararam-se resultados obtidos do modelo MLP 3:9:1 com resultados obtidos de oito dias, que não participaram da etapa de treinamento e validação, representando as 4 estações do ano (Figuras 6, 7, 8 e 9).

Figura 6 - Gráfico Vazão x Tempo - Verão



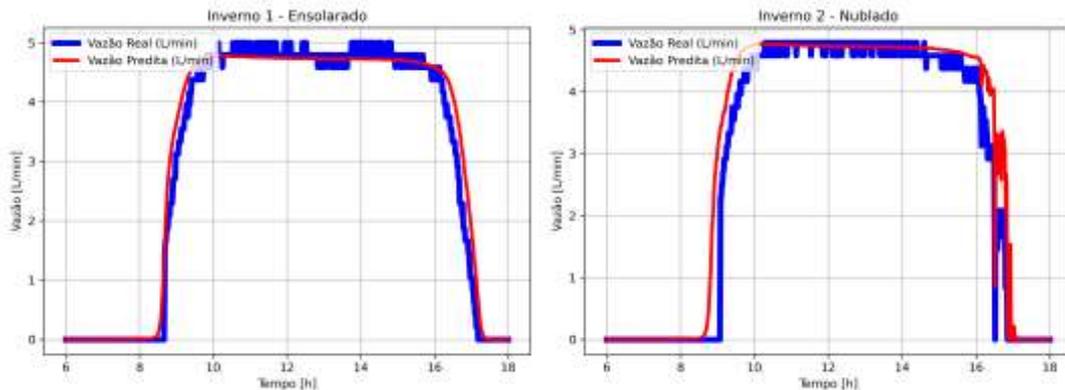
Fonte: Elaborada pelos autores (2023).

Figura 7 - Gráfico Vazão x Tempo - Outono



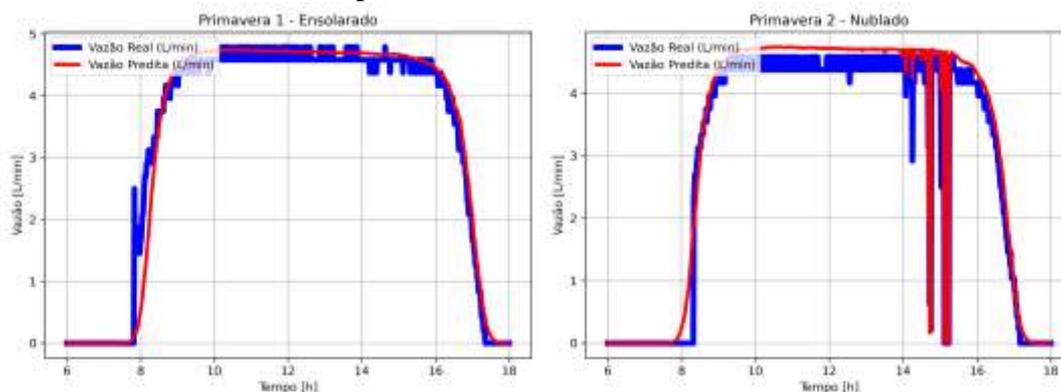
Fonte: Elaborada pelos autores (2023).

Figura 8 - Gráfico Vazão x Tempo - Inverno



Fonte: Elaborada pelos autores (2023).

Figura 9 - Gráfico Vazão x Tempo - Primavera.



Fonte: Elaborada pelos autores (2023).

Nota-se, ao analisar as curvas das Figuras 6, 7, 8, e 9, que existe uma boa aproximação entre os resultados reais e os previstos pelo modelo MLP 3:9:1, tanto para dias bons quanto para dias nublados. Observa-se que cada arquivo de teste, representando cada dia das 4 estações do ano, possui 721 instâncias, com dados das 6 às 18 horas.

3.3 Coeficiente de determinação

Vale destacar que apenas a análise visual não informa com precisão a eficiência dos resultados obtidos. Por isso, para obter uma maior confiabilidade dos resultados, foram calculados os coeficientes de determinação para os oito dias, dois de cada estação do ano. A qualidade de ajuste de um modelo pode ser avaliada pelo coeficiente de determinação. Este coeficiente indica quanto o modelo foi capaz de explicar os dados coletados.

Tabela 3 - Coeficiente de determinação

Estação	R²
Verão 1	0,987
Verão 2	0,984
Outono 1	0,965
Outono 2	0,979
Inverno 1	0,978
Inverno 2	0,974
Primavera 1	0,974
Primavera 2	0,977

Fonte: Elaborada pelos autores (2023).

Observa-se que todos os testes apresentaram coeficiente de determinação na faixa de 0,965-0,987, onde o maior índice encontrado foi para um dia de verão sem nuvens e o menor para um dia de outono nublado. Observa-se também, destes resultados, o bom desempenho da rede neural MLP.

4. Conclusões

Este trabalho teve por objetivo analisar a aplicação de redes neurais artificiais na predição da vazão de um sistema de bombeamento fotovoltaico, localizado na região oeste paranaense.

A base de dados utilizada, neste trabalho, apresenta um histórico de um ano, contendo as variáveis: hora, temperatura, irradiação solar, corrente, tensão e vazão da bomba. Com as variáveis hora, temperatura, irradiação solar e vazão, obtidas deste banco de dados, construíram-se modelos de predição baseados em Redes Neurais Artificiais MLP.

Inicialmente, depois de tratar os dados obtidos do banco de dados, obteve-se, no processo de Treinamento e Validação, o modelo com melhor desempenho (MLP 3:9:1). Na sequência, testou-se este modelo para dados de oito dias, dois de cada estação do ano. Observou-se, destes testes, a existência de uma boa aproximação entre os resultados obtidos de campo e os previstos pela rede. Portanto, conclui-se que o modelo MLP 3:9:1 é adequado para estimativa da vazão da bomba fotovoltaica localizada na região oeste paranaense.

Referências

ANTONELI, G. C.; NEITZELI, I. Aplicação de redes neurais artificiais na indústria de fios de algodão. **GEPROS. Gestão da Produção, Operações e Sistemas**, vol. v. 2, 2016. Disponível em: <https://revista.feb.unesp.br/gepros/article/download/1355/711>. Acesso em: 29 ago. 2023.

BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A. P.; SEPULVEDA, G. P. L. Application of data mining algorithms in the management of the broiler production. **Geintec**, v. 8, n. 4, 2018.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2007.

CONSENZA, D. N. Classificação da capacidade produtiva de sítios florestais utilizando máquina de vetor de suporte e rede neural artificial. **Scientia Florestalis**, 2016. Disponível em: <https://www.ipef.br/PUBLICACOES/SCIENTIA/nr108/cap19.pdf>. Acesso em: 29 ago. 2023.

HADDAD, S. *et al.* ANNs-based modeling and prediction of hourly flow rate of a photovoltaic water pumping system: Experimental validation. **Renewable and Sustainable Energy Reviews**, v. 43, 2015. Disponível em: <https://doi.org/10.1016/j.rser.2014.11.083>. Acesso em: 29 ago. 2023.

Haykin, S. **Neural networks: a comprehensive foundation**. New Delhi: Pearson Prentice Hall, 2001.

JARDIM, C. S. **A inserção da geração solar fotovoltaica em alimentadores urbanos enfocando a redução do pico de demanda diurno**. Tese (Doutorado Programa de Pós-Graduação em Engenharia Civil-PPGEC) - Universidade Federal de Santa Catarina-UFSC, Florianópolis, 2007. Disponível em: <https://repositorio.ufsc.br/xmlui/handle/123456789/90237>. Acesso em: 29 ago. 2023.

KOLLING, E. M. **Análise de um sistema fotovoltaico de bombeamento de água.** Dissertação de Mestrado, Universidade Estadual do Oeste do Paraná, Cascavel, 2001.

MICHELS, R. N. **Avaliação de um sistema de bombeamento de água alimentado por painéis fotovoltaicos.** Dissertação (Mestrado Pós-Graduação em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná-UNIOESTE, Cascavel, 2007. Disponível em: https://riut.utfpr.edu.br/jspui/bitstream/1/429/3/UNIOESTE_%20PGEAGRI_M_Michels%2C%20Roger%20Nabeyama_2007.PDF. Acesso em: 29 ago. 2023.

MORAES, A. M. et al. Análise de gestão e operação de sistemas de bombeamento no semiárido brasileiro. **Revista ASADES**, v. 24, 2020. Disponível em: <https://portalderevistas.unsa.edu.ar/index.php/averma/article/view/1981>. Acesso em: 29 ago. 2023.

OLIVEIRA, G. Qual a relação entre Deep Learning e Machine Learning. Disponível em: <http://bicomvatapa.blogspot.com/2018/02/diferenca-qual-relacao-entre-deep.html>. Acesso em: 13 jan. 2023.

OLIVEIRA, L.; SANTOS, J. A. A. As Redes Neurais Aplicadas à Previsão de Corrente Elétrica de um Sistema Fotovoltaico. **Revista FSA**, v. 19, n. 5, 2022. Disponível em: <https://web.archive.org/web/20220511051806id/http://www4.unifsa.com.br/revista/index.php/fsa/article/download/2419/491493244>. Acesso em: 29 ago. 2023.

OYAMA, P. T. **Vazão de uma motobomba acionada por painéis fotovoltaicos.** Dissertação (Mestrado Pós-Graduação em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná-UNIOESTE, Cascavel, 2008. Disponível em: <https://tede.unioeste.br/bitstream/tede/2755/1/Paulo%20Takashi%20Oyama.pdf>. Acesso em: 29 ago. 2023.

PINHEIRO, T. C.; SANTOS, J. A. A.; PASA, L. A. Gestão da produção de frangos de corte por meio de redes neurais artificiais, **Revista Holos**, 2020. Disponível em: <https://doi.org/10.15628/holos.2020.9043>. Acesso em: 29 ago. 2023.

SANTOS, J. A. A.; CKAUKOSKI, Y. Previsão do consumo de energia elétrica na região sudeste: um estudo de caso usando SARIMA e LSTM. **Revista CEREUS**, v. 12, 2020. Disponível em: <http://ojs.unirg.edu.br/index.php/1/article/view/3255>. Acesso em: 29 ago. 2023.

SANTOS, J. A. A. Aplicação de Redes Neurais na Previsão de Custos de Produção de Frangos de Corte no Estado do Paraná. **Revista FSA**, v. 18, n. 6, 169-185. 2021.

SILVA, E. M.; BASCOPE, R. P. T. Sistema de bombeamento de água usando energia fotovoltaica'. 2020. Disponível em: <https://anaiscbens.emnuvens.com.br/cbens/article/view/915>. Acesso em: 12 jan. 2023.

SUN PUMPS SDS series dc submersibles pumps. Disponível em: <http://www.sunpumps.com/Photo/318?d=3/18/20238:08:20PM>. Acesso em: 12 jan. 2023.