



University of
Texas Libraries



e-revist@s



Centro Unversitário Santo Agostinho

revistafsa

www4.fsnet.com.br/revista

Rev. FSA, Teresina, v. 19, n. 5, art. 8, p. 146-159, mai. 2022

ISSN Impresso: 1806-6356 ISSN Eletrônico: 2317-2983

http://dx.doi.org/10.12819/2022.19.5.8

DOAJ DIRECTORY OF
OPEN ACCESS
JOURNALS

WZB
Wissenschaftszentrum Berlin
für Sozialforschung



As Redes Neurais Aplicadas à Previsão de Corrente Elétrica de um Sistema Fotovoltaico

Neural Networks Applied to Electric Current Forecast of a Photovoltaic System

Leandro de Oliveira

Engenheiro Eletricista pela Universidade Tecnológica Federal do Paraná

E-mail: leandro-smi@hotmail.com

José Airton Azevedo dos Santos

Doutor em Engenharia Elétrica pela Universidade Federal de Santa Catarina

Professor da Universidade Tecnológica Federal do Paraná

E-mail: airton@utfpr.edu.br

Endereço: Leandro de Oliveira

CAMPUS MEDIANEIRA Avenida Brasil, 4232 CEP
85884-000 - Caixa Postal 271 - Medianeira - PR – Brasil

Endereço: José Airton Azevedo dos Santos

CAMPUS MEDIANEIRA Avenida Brasil, 4232 CEP
85884-000 - Caixa Postal 271 - Medianeira - PR – Brasil

**Editor-Chefe: Dr. Tonny Kerley de Alencar
Rodrigues**

**Artigo recebido em 25/11/2021. Última versão
recebida em 08/11/2021. Aprovado em 09/11/2021.**

**Avaliado pelo sistema Triple Review: a) Desk Review
pelo Editor-Chefe; e b) Double Blind Review
(avaliação cega por dois avaliadores da área).**

Revisão: Gramatical, Normativa e de Formatação



RESUMO

Recentemente, com a expansão das indústrias e o crescimento populacional, a demanda por energia elétrica só vem aumentando. Energias renováveis são alternativas para suprir esta demanda. Dentre elas, a energia solar se destaca como uma fonte sustentável e renovável de energia. Nesse contexto, este trabalho tem como objetivo implementar modelos, baseados em redes neurais artificiais e regressão linear múltipla, para predição da corrente elétrica gerada por um sistema solar fotovoltaico, localizado na região oeste paranaense. Modelos, baseados nas arquiteturas *Multilayer Perception* (MLP) e *Linear Regression* (LR), foram implementados na linguagem Python. Resultados obtidos dos modelos, de redes neurais MLP, foram comparados por meio das métricas: CC (*Correlation Coefficient*), MSE (*Mean Squared Error*) e RMSE (*Root Mean Squared Error*). Os resultados sugerem que o modelo de rede neural artificial é mais adequado, para prever a corrente elétrica do sistema fotovoltaico, do que o modelo de regressão linear.

Palavras-chave: Energia Solar. Painel Fotovoltaico. Redes MLP. Regressão Linear.

ABSTRACT

Recently, with the expansion of industries and population growth, the demand for electricity has only been increasing. Renewable energies are alternatives to supply this demand. Among them, solar energy stands out as a sustainable and renewable source of energy. In this context, this work aims to implement models, based on artificial neural networks and multiple linear regression, to predict the electric current generated by a photovoltaic solar system, located in the western region of Paraná. Models, based on Multilayer Perception (MLP) and Linear Regression (LR) architectures, were implemented in Python language. Results obtained, from MLP neural network models, were compared using metrics: CC (*Correlation Coefficient*), MSE (*Mean Squared Error*) and RMSE (*Root Mean Squared Error*). The results suggest that the artificial neural network model is better suited, to predict the electrical current of the photovoltaic system, than the linear regression model.

Keywords: Solar Energy. Photovoltaic Panel. MLP Networks. Linear Regression.

1 INTRODUÇÃO

A demanda por energia vem crescendo rapidamente. Contudo, no momento de suprir esta demanda, deve-se sempre levar em consideração os efeitos negativos associados ao uso de energias não renováveis. A energia solar, alternativa ao uso das energias não renováveis, é uma energia abundante, não poluente e dispersa (ANTONELI; NEITZEL, 2016).

Como exemplo de fontes não renováveis de energia, pode-se citar as usinas termoelétricas. Estas usinas utilizam, para produção de energia, carvão, óleo ou gás. Segundo Jardim (2007), as energias não renováveis contribuem para o efeito estufa, aquecimento global e para catástrofes climáticas.

A utilização de energia solar, por meio de módulos fotovoltaicos, tem se tornado uma boa opção para os consumidores. Pode ser utilizada na geração de eletricidade para iluminação e bombeamento de água (OYAMA, 2008; KOLLING, 2001). Atualmente, existe um considerável crescimento de sistemas fotovoltaicos instalados em residências, principalmente nas regiões sul, sudeste e nordeste. Os sistemas fotovoltaicos podem ser uma alternativa para produção de eletricidade no país. Segundo Araújo *et al.* (2021), a energia solar representa somente 1,7% da matriz energética.

Redes Neurais Artificiais (RNA) estão sendo aplicadas em várias áreas, tais como medicina, engenharia, física, entre outras. Podem ser aplicadas em problemas de regressão, classificação e compactação de dados. As Redes Neurais Artificiais processam os dados de maneira muito parecida ao cérebro humano. Utilizam, no processamento de informações, o princípio de organização de neurônios do cérebro. Portanto, pode-se considerar as Redes Neurais Artificiais como um esquema de processamento capaz de armazenar conhecimento e disponibilizá-lo para determinada aplicação (HAYKINS, 2001; BRAGA *et al.*, 2007; CONSEZA, 2016; OIKAWA, 2014;).

As redes neurais são capazes de memorizar, analisar e processar um grande número de dados obtidos de um experimento. É uma técnica de modelagem que pode resolver muitos problemas complexos (BASTIANI *et al.*, 2018; PINHEIRO, *et al.*, 2020).

Nesse contexto, este trabalho tem como objetivo implementar e analisar modelos, baseados em redes neurais artificiais e regressão linear múltipla, para predição da corrente elétrica gerada por um sistema fotovoltaico, localizado na região oeste paranaense.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção apresentam-se os algoritmos de previsão, utilizados nesta pesquisa, bem como as métricas utilizadas.

2.1 Algoritmos

Neste trabalho foram avaliados dois algoritmos de mineração de dados:

Linear Regression (RL):

Quando o resultado e todos os atributos, de um determinado problema, são numéricos, a regressão linear múltipla, técnica bastante aplicada pela comunidade científica, pode ser considerada. Esta técnica é usada para estudar a relação entre a variável dependente e as variáveis independentes. Esta relação pode ser descrita como uma função linear $y = a_0 + a_1X_1 + \dots + a_nX_n$ tal que $a_i \in \mathbb{R}$ e X_i é uma variável real (CANKURT *et al.*, 2015; SING *et al.*, 2017; BASTIANI *et al.*, 2018, ROZZA *et al.*, 2015). O algoritmo de regressão linear pode ser encontrado em vários softwares estatísticos.

Multilayer Perception (MLP):

As redes MLP representam uma classe de redes neurais muito utilizadas em mineração de dados. A rede é composta por múltiplas camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Em cada camada têm-se nós e cada um dos nós está interligado, por meio de pesos, aos nós da camada subsequente (TISSOT *et al.*, 2012). Utiliza o algoritmo *backpropagation* para o treinamento da rede. O *backpropagation*, desenvolvido nos anos 80, é um dos algoritmos mais conhecidos das redes neurais. As redes MLP podem realizar tanto regressão quanto classificação (SANTOS *et al.*, 2013; SEBASTIAN, 2016; BASTIANI *et al.*, 2018; PINHEIRO, *et al.*, 2020).

2.2 Métricas

Os modelos obtidos, das redes neurais, são avaliados pelos parâmetros: Coeficiente de Correlação (*Correlation Coefficient*), Erro Médio Quadrático (*Mean Squared Error*) e Raiz Quadrada do Erro Médio quadrático (*Root Mean Squared Error*).

Correlation Coefficient (CC) - Mede o grau de associação linear entre os dados previstos e observados.

Mean Squared Error (MSE)- É uma forma de avaliar a diferença entre um estimador e o verdadeiro valor da quantidade estimada (Equação 1).

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

Root Mean Squared Error (RMSE)- Raiz do erro médio quadrático da diferença entre a predição e o valor real (Equação 2).

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

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.


3 METODOLOGIA

O sistema fotovoltaico, utilizado neste trabalho, está instalado nas dependências da Universidade Tecnológica Federal do Paraná (UTFPR), campus de Medianeira, localizada na Av. Brasil, 4232, Medianeira, região oeste do estado do Paraná. As coordenadas geográficas da localização do painel fotovoltaico são 25°18'2.1" Sul e 54°6'54.5" Oeste, com uma elevação de 422m acima do nível do mar.

3.1 Materiais utilizados

O sistema solar fotovoltaico foi composto pelos seguintes elementos:

- Dois módulos solares do fabricante Solarex, modelo MSX 56, tensão padrão de 12V, corrente padrão de 3,35A e potência de 56W (Figura 1);
- Um micrologger Campbell da Scientific-Inc modelo CD 23 X;
- Um termopar do tipo K (cromo-alumínio) aferido;
- Um microcomputador;
- Dois piranômetros Kipp&Zonen modelo CM3;
- Um divisor de tensão e uma resistência Shunt;
- Uma motobomba, fabricante Shurflo Ltd, modelo 2088-732-244, tensão de 12 V.

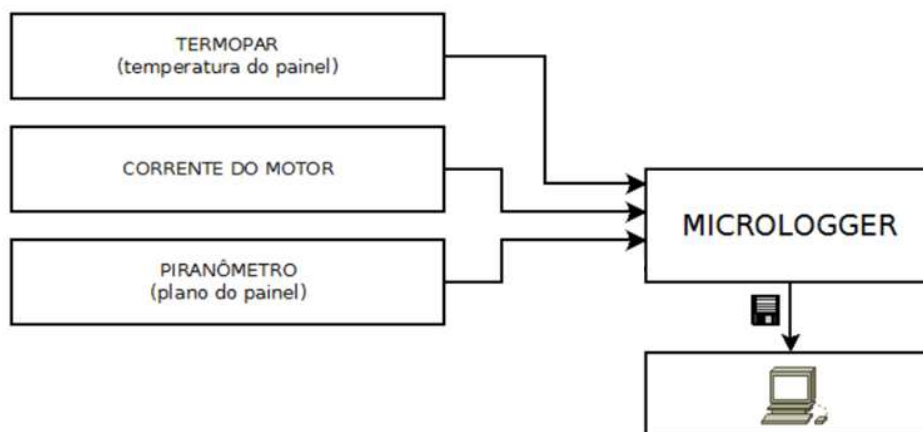
Figura 1 – Pannel fotovoltaico

Fonte: Michels (2007).

O objetivo de citar as marcas neste trabalho não possui a intenção de recomendar os produtos, e sim proporcionar a identificação dos equipamentos que foram utilizados para obter-se os dados.

3.2 Base de dados

A leitura e captação dos dados de Corrente, Temperatura e Irradiação Solar Global foi realizada por meio do micrologger (Figura 2). A leitura foi realizada durante intervalos de 5 segundos em cada canal, posteriormente foi calculada a média desses valores num período de cinco minutos.

Figura 2 – Esquemático de interligação dos elementos de coleta de dados

Fonte: Michels (2007).

Os dados de Corrente, Temperatura e Irradiação Solar Global foram divididos em três conjuntos. O primeiro conjunto, Conjunto de Treinamento, foi formado pelos primeiros 12460 dados. O segundo conjunto, o Conjunto de Validação, foi constituído pelos seguintes 6420 dados. Finalmente, os Conjuntos de Teste foram formados por 721 dados. Os arquivos de Teste foram divididos em 4 estações do ano, sendo que para cada estação foram separados dois dias, um dia ensolarado e um dia nublado.

3.3 Limpeza e tratamento dos dados

Na fase inicial deste trabalho, seguiram-se as seguintes etapas:

- a) Limpeza de dados: Nesta etapa deve ocorrer a remoção de dados inconsistentes;
- b) Seleção dos dados: Nesta etapa os dados relevantes para a análise são retirados do banco de dados;
- c) Transformação dos dados: etapa na qual os dados são transformados para serem utilizados pelo algoritmo. Por exemplo, normalização dos dados na faixa de valores entre 0 e 1.

3.4 Recursos de software e hardware

Para implementação do algoritmo, foi utilizada a IDE Spyder versão 3.3.2 (Ambiente de Desenvolvimento Integrado) em conjunto ao Jupyter Notebook (Integrado a IDE). As bibliotecas de aprendizado de máquina: Scikit-learn, Pandas, Matplotlib e Keras foram também utilizadas. Scikit-learn é uma biblioteca de aprendizado de máquina, para a linguagem Python, que inclui vários algoritmos de classificação, regressão e agrupamento. Matplotlib é a mais famosa biblioteca de visualização de dados do Python. A biblioteca Pandas fornece ferramentas de análise de dados e estrutura de dados de alta performance. Keras é uma biblioteca para rede neural de alto nível escrita em Python e roda como *frontend* em TensorFlow ou Theano.

Os algoritmos foram executados por um notebook com o sistema Linux Mint 18.3. O notebook conta com um processador Intel® T4400 Dual-Core, 2,2GHz e 2GB de memória RAM.

4 RESULTADOS E DISCUSSÕES

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 1).

Tabela 1 – Análise descritiva de dados


Parâmetro	Temperatura (°C)	Irradiância (W/m ²)	Corrente (A)
Instâncias	18880	18880	18880
Média	33,14	574,29	1,15
Mínimo	5,42	0	0
Máximo	60,6	1095	1,78
Desvio Padrão	13,23	342,56	0,55
Coefficiente de Variação (%)	39,92	59,65	47,83

Pode-se notar, dos dados apresentados na Tabela 1, que o sistema em estudo apresenta uma temperatura média de 33,14°C, uma irradiação média de 574,29W/m² e uma corrente elétrica média de 1,15A. Observa-se também que os coeficientes de variação estão um pouco altos. Segundo Pimentel (2000), nos experimentos de campo, se o coeficiente de variação for inferior a 10% tem-se um coeficiente de variação baixo, de 10 a 20% médio, de 20 a 30% alto e acima de 30% muito alto.

Após realizar a análise exploratória, os dados foram plotados em forma de *boxplots*, para identificação de *outliers* (valores fora da normalidade). As razões mais comuns para o surgimento de *outliers* são os erros na coleta de dados ou eventos raros e inesperados. Os *outliers* considerados como extremos só foram descartados das amostras depois de uma análise criteriosa de suas causas. Os valores julgados como possíveis de ocorrer foram mantidos nas amostras. Observa-se que a presença destes valores pode causar distorções nos modelos, tornando-os menos confiáveis.

Na Figura 3 apresenta-se, como exemplo, o *boxplot* da Temperatura.

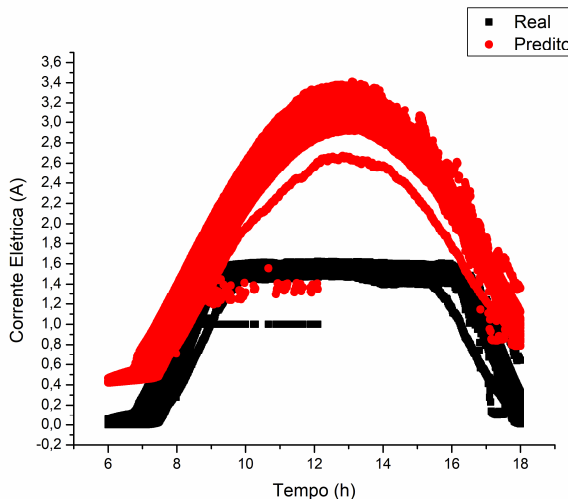
Figura 3 – Boxplot da temperatura



4.1 Regressão linear

Na sequência compararam-se os valores preditos pelo algoritmo de Regressão Linear com relação aos valores observados (Reais) para a variável de resposta (Figura 4).

Figura 4 – Dados reais e preditos



Observa-se, da Figura 4, que o algoritmo de Regressão Linear não apresenta, devido às características de não linearidades dos dados, uma boa aproximação com os dados observados (Reais). Portanto, na sequência deste trabalho, testa-se somente o algoritmo da RNA.

4.2 Redes neurais – conjunto de validação

Neste trabalho, vários modelos de redes neurais MLP foram testados, utilizando como indicadores de desempenho as métricas *Correlation Coefficient* (CC), *Mean Squared Error* (MSE) e *Root Mean Squared Error* (RMSE). As redes neurais foram treinadas com 12460 amostras (66%) e validadas com 6420 amostras (34%). 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;

Activation Function = Sigmoid.

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

Tabela 2 – Resultados - Métricas

Parâmetro	RNA
<i>Correlation Coefficient</i>	0,9933
<i>Mean Squared Error</i>	0,0006
<i>Root Mean Squared Error</i>	0,025

4.2 Redes neurais – conjuntos de teste

Para testar o modelo da RNA, compararam-se resultados obtidos do algoritmo com resultados obtidos de oito dias, que não participaram da etapa de treinamento e validação, representando as 4 estações do ano (Figuras 5, 6, 7, 8).

Figura 5 – Gráficos da Corrente x Tempo – dias de Inverno

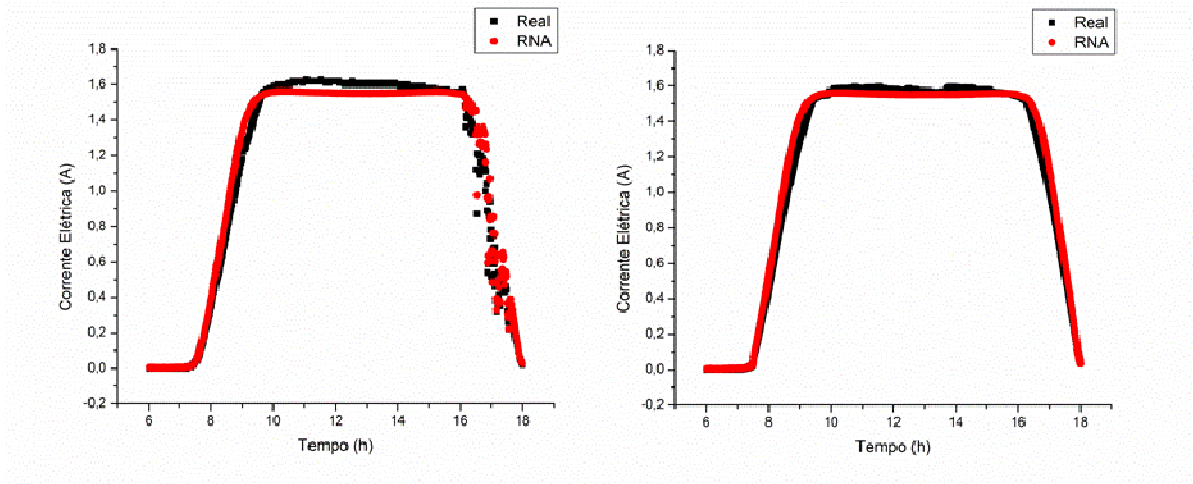


Figura 6 – Gráficos da Corrente x Tempo – dias de Outono

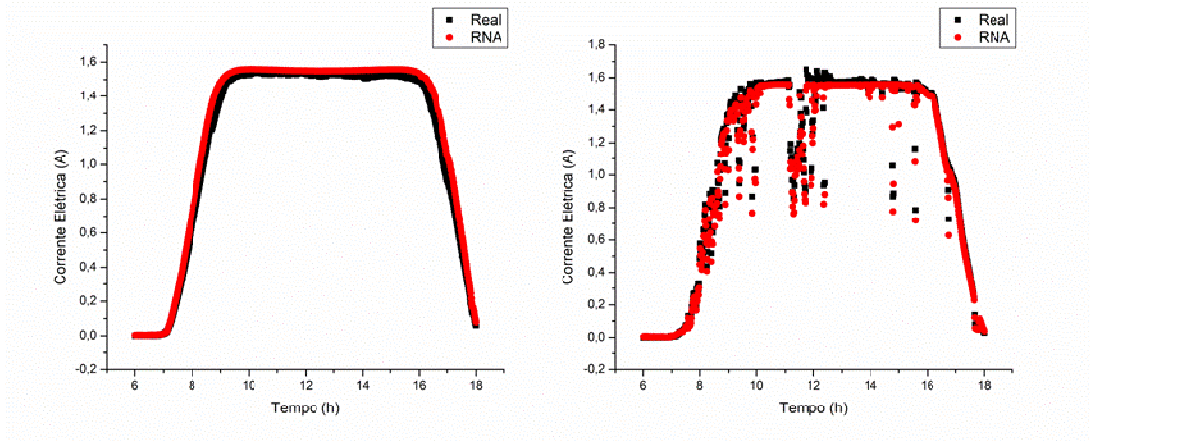


Figura 7 – Gráficos da Corrente x Tempo – dias de Primavera


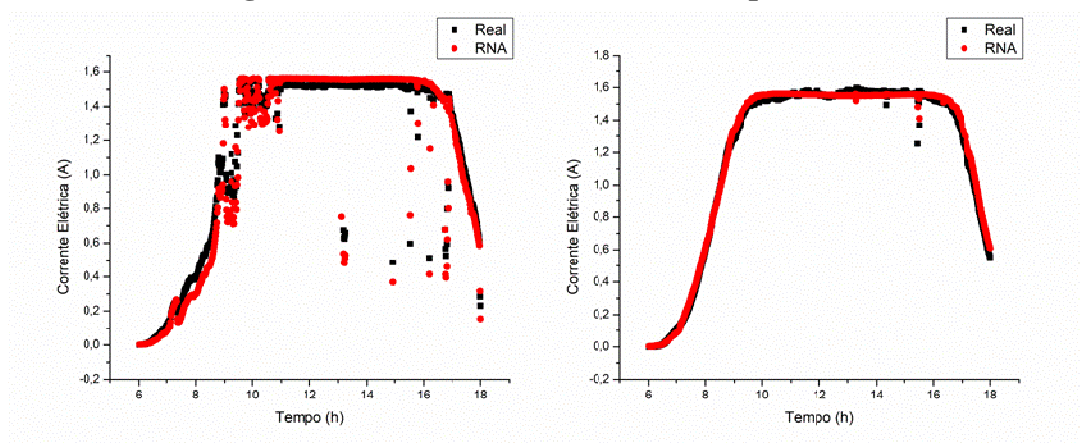


Figura 8 – Gráficos da Corrente x Tempo – dias de Verão



Pode-se observar, por meio dos gráficos apresentados nas figuras, que existe uma boa aproximação entre os resultados reais e o previsto pelo algoritmo RNA, tanto para dias bons quanto para dias nublados.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve por objetivo analisar a aplicação de algoritmos de mineração de dados na predição da corrente elétrica de um sistema fotovoltaico, localizado na região oeste paranaense.

Inicialmente, concluiu-se, neste trabalho, que o problema em estudo mostrou-se bastante não linear, porque foi claramente observado um ganho da rede neural artificial sobre o modelo puramente linear. Isso se deve a uma das habilidades mais importantes das redes neurais que é a capacidade de ajuste de não-linearidades.

Observou-se também a existência de uma boa aproximação entre os resultados obtidos de campo e os previstos pela rede. Esses resultados poderiam ser ainda melhores, se os dados apresentados na rede tivessem uma melhor qualidade, no caso em questão um baixo coeficiente de variação. Observando-se que o ajuste das redes neurais capazes de simular não-linearidades e reconhecer padrões específicos é ligado à quantidade e à qualidade dos dados apresentados.

De modo geral, pode-se concluir, com este estudo, que o modelo de rede neural MLP, implementado neste trabalho, apresentou um desempenho favorável na previsão da corrente elétrica gerada pelo painel fotovoltaico.

REFERÊNCIAS

- ANTONELI, G. C.; NEITZEL, I. Aplicação de redes neurais artificiais na indústria de fios de algodão. **Gestão da Produção, Operações e Sistemas**, 2016.
- ARAÚJO, A. S *et al.* utilização da energia solar de forma mais inteligente, buscando minimizar recursos e maximizar eficiências, por meio de um protótipo. **Revista Mythos**, 2021.
- BASTIANI, M *et al.* Application of data mining algorithms in the management of the broiler production. **Geintec**, vol. 8, 2018.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2007
- CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 2015.
- CONSENZA, D. N. Classificação da capacidade produtiva de sítios florestais utilizando máquina de vetor de suporte e rede neural artificial. **ScientiaFlorestalis**, 2016.
- HAYKINS, S. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001.
- JARDIM, C. S.A **Inserção da geração solar fotovoltaica em alimentadores urbanos enfocando a redução do pico de demanda diurno**. Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, 2007.
- KOLLING, E. M. **Análise de um sistema fotovoltaico de bombeamento de água**. Dissertação de Mestrado, Universidade Estadual do Oeste do Paraná, 2001.
- MICHELS, R. N. **Avaliação de um sistema de bombeamento de água alimentado por painéis fotovoltaicos**. Dissertação de Mestrado; Universidade Estadual do Oeste do Paraná, Cascavel, 2007.
- OIKAWA R. T. Modelos estatísticos e de redes neurais artificiais utilizados na predição de precipitação. **Periódico Eletrônico Fórum Ambiental da Alta Paulista**, 2014.
- OYAMA, P. T. **Vazão de uma motobomba acionada por painéis fotovoltaicos**. Dissertação de Mestrado, Universidade Estadual do Oeste do Paraná, Cascavel, 2008.
- PIMENTEL, G. F. **Curso de estatística experimental**. Piracicaba: Degaspari, 2000.
- PINHEIRO, T. C.; SANTOS, J. A. A.; PASA, L. A. Gestão da produção de frangos de corte por meio de redes neurais. **Revista Holos**, 2020.
- ROZZA, G. L.; SILVA, R. G.; MULLER, S. I. M. G. Estudo comparativo do uso de redes neurais artificiais e regressão linear múltipla para a previsão da concentração cáustica em uma etapa do processo de fabricação de alumina. **Produção Online**, 2015.

SANTOS, R. B *et al.* Comparison between multilayer feedforward neural networks and a radial basis function network to detect and locate leaks in pipelines transporting gás. **Chemical Engineering Transactions**, 2013.

TISSOT, H. C.; CAMARGO, L. C.; POZO, A. T. R. Treinamento de redes neurais feedforward: comparativo dos algoritmos backpropagation e differential evolution. **In...** Conference: Brazilian Conference on Intelligent Systems, 2012. Curitiba, 2012.

WITTEN, I. H.; FRANK E. **Data mining**: practical machine learning tools and techniques. San Francisco: Morgan Kaufmann, 2005.

Como Referenciar este Artigo, conforme ABNT:

OLIVEIRA, L; SANTOS, J. A. A. As Redes Neurais Aplicadas à Previsão de Corrente Elétrica de um Sistema Fotovoltaico. **Rev. FSA**, Teresina, v.19, n. 5, art. 8, p. 146-159, mai. 2022.

Contribuição dos Autores	L. Oliveira	J. A. A. Santos
1) concepção e planejamento.	X	X
2) análise e interpretação dos dados.	X	X
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X
4) participação na aprovação da versão final do manuscrito.	X	X