

Aplicação de Redes Neurais Artificiais para Previsão de Velocidade de Vento Considerando Variáveis Correlacionadas

Denise S. Melo*. Leonardo W. Oliveira.*
Janaína G. Oliveira*

*Federal University of Juiz de Fora, José Lourenço Kelmer, s/n, University Campus, 36036-900, Juiz de Fora, Brazil (Tel: 55-32-2102-3444; e-mail: denise.melo@engenharia.ufff.br).

Abstract: The wind speed consists in a random variable whose forecast is important to many areas, as the electrical power system operation planning with photovoltaic energy penetration. This variable is function of other random variables, as wind speed itself in previous moments, global radiation and temperature. Artificial Neural Networks (ANN) have frequently been used in building models to solve problems related to temporal series forecast in different areas. Thus, the present paper presents an ANN implementation, trained with data extracted from a meteorological station located in Juiz de Fora City, which purpose is to predict future wind speed from past values of correlated random variables.

Resumo: Velocidade de vento consiste em uma variável aleatória cuja previsão é importante para diversas áreas, como o planejamento da operação de sistemas elétricos de potência com penetração de energia fotovoltaica. Esta variável é função de outras variáveis aleatórias, como a própria velocidade de vento em momentos anteriores, radiação global e temperatura. Redes Neurais Artificiais (RNA) vêm sendo utilizadas com frequência na construção de modelos para solucionar problemas relacionados à previsão de séries temporais em diferentes áreas. Sendo assim, o presente trabalho apresenta a implementação de uma RNA, treinada com dados extraídos de uma estação meteorológica localizada na cidade de Juiz de Fora, cujo propósito é prever velocidade de vento futura a partir de valores passados das variáveis aleatórias correlacionadas.

Keywords: Wind speed; forecast; artificial neural networks; global radiation; air temperature.

Palavras-chaves: Velocidade de vento; previsão; redes neurais artificiais; radiação global; temperatura do ar.

1. INTRODUÇÃO

Prever dados meteorológicos como velocidade do vento e radiação solar, mesmo com um dia de antecedência, envolve incertezas. Parte da incerteza é relacionada ao fato de a incidência de radiação solar na superfície, assim como a velocidade do vento, ser dependente de condições meteorológicas, especialmente nuvens, temperatura do ar, umidade, envolvendo processos físicos não-lineares de transmissão de radiação, entre outros. Além disso, existem as incertezas relacionadas à própria imprecisão na obtenção de previsões das condições de tempo futuras pelos modelos numéricos, bem como de propriedades óticas do estado atmosférico futuro, devido à natureza caótica e não-linear da evolução do tempo meteorológico (Guarnieri et al. 2007). Esta previsão é fundamental para a avaliação de impactos de geração renovável em Sistemas Elétricos de Potência (SEP), no âmbito do planejamento e da operação destes sistemas.

As Redes Neurais Artificiais (RNA) vêm sendo utilizadas com frequência na construção de modelos para solucionar problemas relacionados à previsão de séries temporais em diferentes áreas. Previsões de curto prazo direcionadas ao setor de energia são empregadas em diversas análises, principalmente quando se trata de energia renovável, como

no planejamento da operação visando otimização no aproveitamento de recursos energéticos distribuídos.

Neste contexto, métodos baseados em inteligência artificial têm sido propostos para prever a conversão de energia renovável utilizando informações ambientais (Hyama et al. 1997). Hiyama et al. (1997) apresentam uma aplicação de RNA para estimar potência fotovoltaica a partir de informações de irradiância, temperatura ambiente e velocidade de vento. Em Mellit et al. (2013), dois modelos de RNA são desenvolvidos, um para dia nublado e outro para dia ensolarado, utilizando apenas informações ambientais de irradiância e temperatura. Riley et al. (2012) utilizam RNA para monitorar estado de conservação de sistemas fotovoltaicos. Em Huang et al. (2016), RNA é utilizada para a estimativa de potência fotovoltaica, introduzindo como entradas os ângulos de zênite e de azimute solar, entre a irradiância e a temperatura.

No que tange à previsão de velocidades de vento, Doucoure et al. (2016) propõem um método de previsão de séries temporais utilizando RNA. Esta utilização também é verificada em Catalão et al. (2011), em combinação com a transformada *wavelet* para previsão de energia eólica a curto prazo. Chang et al. (2017) apresentam um método de

previsão de velocidade de ventos e geração eólica em curto prazo, baseado em RNA com função de base radial, aprimorada com um esquema de *feedback* de erro. Com o mesmo propósito, um método de previsão de intervalo multiobjetivo baseado em RNA *wavelet* é proposto por Shi et al. (2018).

Seguindo a linha de pesquisa anterior, o presente trabalho apresenta a implementação de uma RNA, treinada com dados extraídos de uma estação meteorológica localizada na cidade de Juiz de Fora, com o objetivo de prever velocidades de vento. Como variáveis de entrada, a RNA utiliza as variáveis: i) velocidade de ventos; ii) temperatura do ar; iii) radiação global. Testes são realizados a fim de verificar o impacto destas variáveis no problema de previsão proposto. Os testes demonstram potencial de aplicação de RNA ao problema, bem como o efeito das variáveis estocásticas propostas para a previsão.

O artigo está organizado da seguinte maneira: a seção II apresenta os dados e a metodologia utilizada nas simulações, subdividida em: Redes Neurais Artificiais; conjunto de dados meteorológicos utilizados; índices de desempenho. A seção III apresenta os resultados das simulações, subdividida em: previsão do vento de uma hora seguinte às horas anteriores informadas; previsão de vento de uma hora seguinte às horas anteriores informadas, com inserção da radiação global; previsão de vento de uma hora seguinte às horas anteriores informadas, com inserção da temperatura do ar e; previsão de vento de uma hora seguinte às horas anteriores informadas, com inserção da radiação global e temperatura do ar; previsão de vento de vinte quatro horas (um dia) seguinte às noventa e seis horas (quatro dias) anteriores informadas, com inserção da radiação global e temperatura do ar. Por fim, na seção IV, são apresentadas as conclusões deste trabalho.

2. DADOS E METODOLOGIA

2.1 Redes Neurais Artificiais

O funcionamento do cérebro humano por ser um órgão complexo na maneira do seu funcionamento, vem sendo alvo de estudos científicos durante muitos anos, sendo de grande valia para estudos computacionais quando esses são traduzidos em linguagens de programação. Em et al. Simon (1999), uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para uso. Se tratando do setor elétrico, as redes neurais artificiais são encontradas em diversas aplicações, tais como: previsão de carga em curto prazo em redes de distribuição (Ferro et al. 2009), a previsão de eficiência de geração de energia elétrica por meio de placas fotovoltaicas (Rampinelli et al. 2010) e como ferramenta auxiliar para a quantificação de variações de tensão de curta duração (das Mercedes et al. 2009).

As redes neurais artificiais (RNAs) são amplamente usadas para aproximar a relação não-linear entre os conjuntos de dados de entrada e saída devido à estrutura matemática flexível. A principal vantagem da RNA é que nenhum conhecimento específico do problema é necessário, mas ele

aprende respostas a padrões com exemplos treinados (Benghanem et al. 2009). Neste trabalho é utilizado uma rede neural feedforward com algoritmo backpropagation (BP) (Huang et al 2016).

A rede consiste em três camadas: a camada de entrada, a camada oculta e a camada de saída. Esse tipo de rede pode ser usada para ajustar qualquer tipo de entrada finita ao problema de mapeamento de saída com neurônios suficientes na camada oculta. A camada de entrada aceita entradas de um M -vetor dimensional, X ; a camada oculta, H , é composta por N neurônios; e a camada de saída, Y , possui Q saídas (Huang et al. 2016). As conexões entre as camadas são apresentadas em (1) e (2):

$$h_j = f_H(\sum_{i=1}^M x_i \omega_{i,j} + b_j), \text{ para } j = 1 \dots N \quad (1)$$

$$y_q = f_Y(\sum_{j=1}^N h_j \omega'_{j,q} + b'_q), \text{ para } q = 1 \dots Q \quad (2)$$

Onde x_i , h_i e y_q são, respectivamente, i th elemento de entrada, a j th saída da camada oculta e o q th elemento da camada de saída; $\omega_{i,j}$ é o peso do i th elemento de entrada ao j th neurônio da camada oculta, e $\omega'_{j,q}$ é o peso do j th neurônio da camada oculta ao q th neurônio da camada de saída; b_j e b'_q são os biases de j th neurônio da camada oculta e q th neurônio da camada de saída, respectivamente; f_H e f_Y são as funções de transferência para a camada oculta e a camada de saída, respectivamente.

As três funções de transferência mais usadas para redes multicamadas são: a função linear, a função sigmóide logarítmica e a função sigmóide tangente hiperbólica. Neste trabalho foi utilizada a função de transferência não-linear sigmóide tangente hiperbólica na camada oculta e de saída a função linear.

O problema de mapeamento de entrada-saída ($X - Y$) é então convertido para determinar o número de neurônios na camada oculta e para determinar os pesos e desvios da rede. Aumentar o número de neurônios na camada oculta melhora o poder da rede, no entanto, é necessário mais cálculo e a rede corre mais risco de sofrer sobre-ajuste. O processo para obter pesos e biases ideais é conhecido como treinamento da rede. O processo de treinamento, ajustando pesos e desvios, é otimizar o desempenho da rede definido por uma função de objetivo de desempenho, como erro médio quadrático, o erro quadrado médio entre a saída da rede e o destino. O valor inicial de peso e bias pode influenciar os resultados do treinamento (Huang et al. 2016).

2.2 Conjunto de Dados Utilizados

Para este trabalho, foram coletados dados climáticos de radiação global (kJ/m^2), temperatura do ar ($^{\circ}\text{C}$), velocidade do vento (m/s), sendo estes dados dispostos de forma horaria totalizando 31 dias com 24 horas cada, para o mês de janeiro de 2008 em Juiz de Fora - MG (Brasil). Esses dados serviram como dados de entrada para a preparação da rede. Juiz de Fora se localiza no Estado de Minas Gerais na Zona da Mata Mineira, caracterizando se por ser um município com clima tropical de altitude com temperatura média anual de 19°C . A Fig. 2 apresenta a média dos dados utilizados horários (mês).

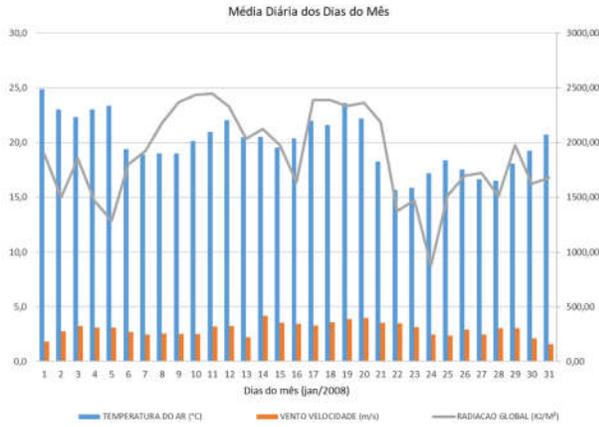


Fig. 2 – Temperatura do ar, velocidade do vento e radiação global médias diárias.

No eixo y está representado dos dois lados do gráfico da Fig. 2, onde o lado esquerdo tem os dados de temperatura e a velocidade do vento, e no lado direito a radiação global. No eixo x estão os dias do mês de janeiro de 2008. A Tabela 1 consta o número de amostras horários utilizadas para o treinamento, teste e validação por tipo de dados utilizado (treinamento 50%; teste 25% e validação 25%).

Tabela 1. Número de Amostras

Nº de Amostras	Treinamento	Teste	Validação
Temperatura do Ar	360	192	192
Velocidade do Vento	360	192	192
Radiação Global	360	192	192
Total	1080	576	576

2.3 Índices de Desempenho

Foram utilizadas ferramentas estatísticas para se obter o desempenho da rede neural em estudo, como as métricas: o valor médio absoluto do erro percentual (MAPE), a raiz do erro médio quadrático (RMSE) e o coeficiente U de Theil. O valor médio absoluto do erro percentual (do inglês MAPE - *mean absolute percentage error*) é uma medida estatística da precisão de séries temporais, representando essa precisão em forma de porcentagem (da Silva et al. 2017) e pode ser definida por (3):

$$MAPE = \frac{\sum_{k=i}^N \left| \frac{a_k - y_k}{a_k} \right|}{N} \times 100\% \quad (3)$$

Sendo:

- N: número de previsões realizadas;
- a_k : saída desejada para a previsão índice “k”;
- y_k : saída prevista para a previsão índice “k”.

Outra ferramenta estatística utilizada é o erro médio quadrático (do inglês RMSE - Root Mean Square Error). Está métrica penaliza muito mais os erros maiores. Desta forma, uma técnica que apresente ótimos resultados na maioria das previsões, porém tenha erros elevados em uma previsão específica, irá fornecer um alto RMSE (Mentaschi et al 2013). O RMSE é definido por (4).

$$RMSE = \frac{1}{N} \sum_{k=i}^N \sqrt{\left| \frac{a_k - y_k}{a_k} \right|^2} \quad (4)$$

Sendo a_k e y_k os dados de entrada e previstos, respectivamente. Pode-se dizer que quanto menores forem os valores do MAPE e do RMSE, melhor é o desempenho da rede neural (Olatomiwa et al. 2015).

Para auxiliar no julgamento do comportamento de um modelo de regressão, Theil (Theil et al. 1966) propôs um índice conhecido na literatura como coeficiente U de Theil que avalia o desempenho de uma estimativa em relação à previsão trivial ou ingênua. Uma previsão ingênua indica que o valor calculado no tempo t é apenas o valor da última observação no tempo anterior t-1. Qualquer modelo de previsão para séries temporais, linear ou não-linear, deve apresentar como requisito mínimo um desempenho superior ao da previsão ingênua. O coeficiente U de Theil é definido pela equação (5).

$$U = \sqrt{\frac{\sum_{k=i}^N (a_k - y_k)^2}{\sum_{k=i}^N (a_k - a_{k-1})^2}} \quad (5)$$

O valor do coeficiente U de Theil analisa-se a qualidade de uma previsão em relação à estimativa ingênua, se:

- $U > 1$, o erro da estimativa é maior que o erro da previsão ingênua.
- $U < 1$, o erro da estimativa é menor que o erro da previsão ingênua.
- Quanto mais próximo de zero for este coeficiente, melhor a previsão.

3. RESULTADOS

Após inserido os dados de entrada de acordo (24 horas x 31 dias) com os cenários apresentados nas simulações (radiação global e temperatura do ar) e os dados de objetivo (velocidade do vento), foi feito o treinamento e o primeiro resultado analisado foi o número de iterações necessárias para que a RNA fosse treinada e validada. A Tabela 1 apresenta as características e parâmetros da RNA utilizada. Esta RNA foi projetada para gerar uma saída, ou seja, prever uma hora a frente. Também foi realizada uma simulação com uma entrada de 96 horas (4 dias) para prever 24 horas a frente (1 dia). O conjunto de amostras, referente a dados de 31 dias, foi dividido como: treinamento 50%; teste 25% e validação 25%. Os parâmetros de simulação da *toolbox* utilizada no MATLAB® estão apresentadas na Tabela 2.

Tabela 2. Parâmetros da RNA

Método de Treinamento	<i>Backpropagation</i>
Nº Neurônios da Camada Oculta	18
Nº Neurônios da Camada de Saída	1
Fç de Ativ.o Camada Oculta	Sigmoide tangente hiperbólica ('tansig')
Fç de Ativ. Camada de Saída	Linear ('purelin')
Nº. entradas (hr anteriores)	4
Nº. saídas (hr a frente a ser prevista)	1
Épocas de treinamento (máximo)	1e5
Erro quadrático máximo	1-6

A RNA inclui um número de entradas igual a 4, ou seja, dados de quatro horas anteriores para prever a velocidade de ventos 1 hora à frente. Também foi feita a RNA incluindo um número de entradas igual a 96, ou seja, dados de 96 horas anteriores para prever a velocidade de ventos 24 hora à frente. Destaca-se ainda, que esta configuração de rede neural foi obtida através de testes empíricos, envolvendo outros valores de números de neurônios na camada oculta, e que o valor obtido de 18 neurônios na camada oculta e 1 neurônio na camada de saída foi o que apresentou o melhor desempenho

As simulações a seguir diferenciam-se quanto aos parâmetros de entrada, como: Simulação-1: somente velocidades de vento como entrada; Simulação-2: velocidades de vento e temperatura do ar como entradas; Simulação-3: velocidades de vento e radiação global como entradas; Simulação-4: velocidade de vento, temperatura do ar e radiação global como entradas; Simulação-5: velocidade de vento, temperatura do ar e radiação global como entradas considerando 4 dias anteriores para prever o próximo dia. As Figuras de 3 e 12 ilustram a evolução dos erros quadráticos durante as épocas de treinamento e a saída da RNA confrontada com os valores reais observados, respectivamente as Simulações de 1 a 5, assim como as tabelas de 2 a 7 que apresentam as métricas utilizadas para encontrar o desempenho da RNA.

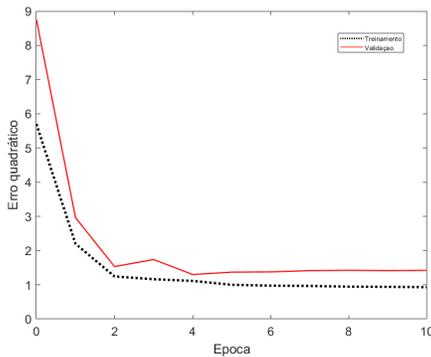


Fig. 3 – Erro Quadrático, Simulação-1

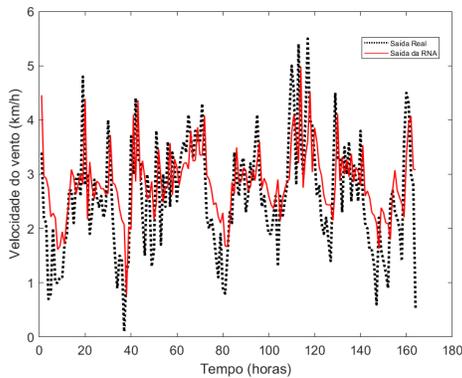


Fig. 4 – Saída da RNA, Simulação-1

Tabela 3. Resultados, Simulação-1

MAPE	26,9865%
RMSE	0,88289
Theil	0,67873

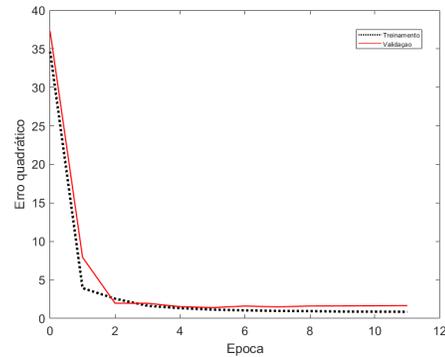


Fig. 5 – Erro Quadrático, Simulação-2

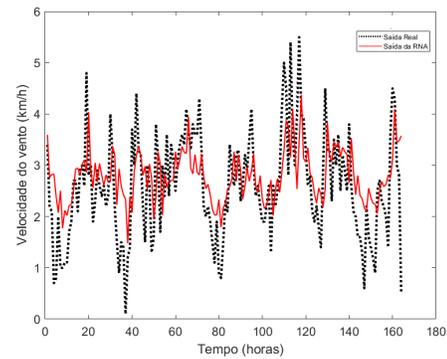


Fig. 6 – Saída da RNA, Simulação-2

Tabela 4. Resultados, Simulação-2

MAPE	25,9262%
RMSE	0,88732
Theil	0,68213

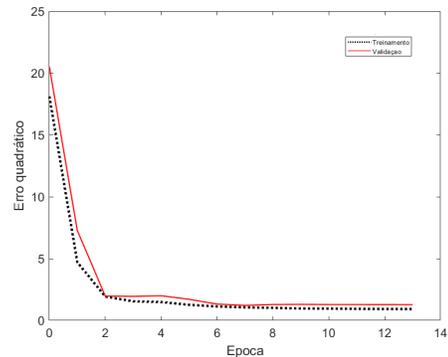


Fig. 7 – Erro Quadrático, Simulação-3

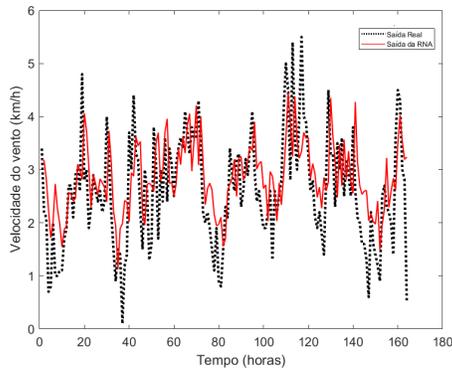


Fig. 8 – Saída da RNA, Simulação-3

Tabela 5. – Resultados, Simulação-3

MAPE	25,917%
RMSE	0,88755
Theil	0,68231

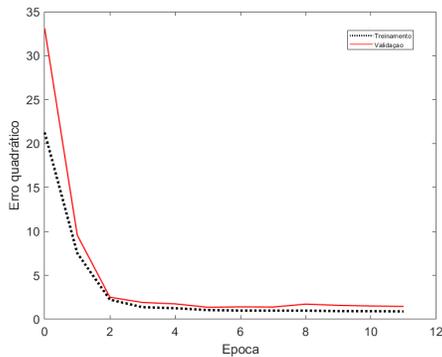


Fig. 9 – Erro Quadrático, Simulação-4

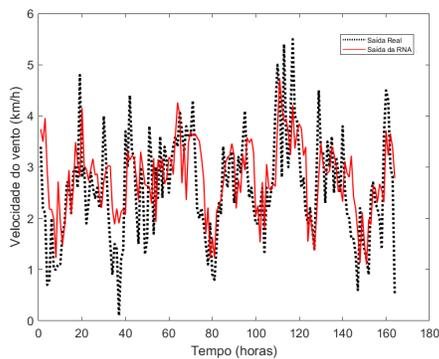


Fig. 10 – Saída da RNA, Simulação-4

Tabela 6. Resultados, Simulação-4

MAPE	25,7905%
RMSE	0,85324
Theil	0,65593

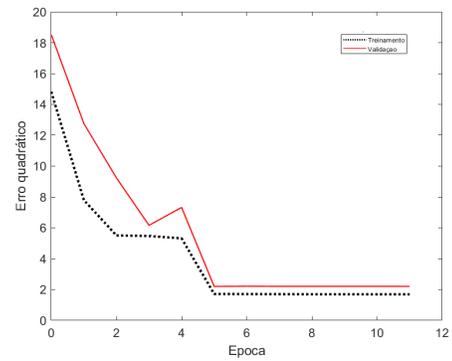


Fig. 11 – Erro Quadrático, Simulação-5

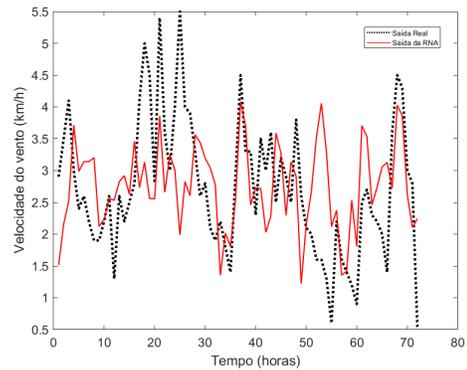


Fig. 12 – Saída da RNA, Simulação-5

Tabela 7. Resultados, Simulação-5

MAPE	33,924%
RMSE	1,0849
Theil	1,0042

Conclui-se, que a temperatura do ar e a Radiação Global nas Simulação-2 e 3 apresentaram resultados similares em relação a correlação com a variável estocástica de interesse a velocidade de ventos. Na Simulação-4, a inclusão das variáveis de radiação global e temperatura do ar melhorou ligeiramente os resultados, em relação às Simulação-2 e 3, embora os resultados sejam muito próximos. Na Simulação-5 os resultados foram piores que as demais, devido ao comportamento da velocidade de vento ser mais instável, mostrando que em períodos mais curtos a correlação apresenta melhores resultados. Este aspecto deverá ser investigado em trabalhos futuros.

Tabela 8. Resultados, Simulações Geral

	S-1	S-2	S-3	S-4	S-5
MAPE	26,987%	25,926%	25,917%	25,791%	33,924%
RMSE	0,8829	0,8873	0,8876	0,8532	1,0849
Theil	0,6788	0,6821	0,6823	0,6559	1,0042

Na Fig. 13 apresenta o diagrama *box plot* (MathWorks et al. 2020) da Simulação-4, sendo a que apresentou melhores resultados conforme Tabela 6. A RNA apresenta comportamento aleatório, porém a dispersão das 100

execuções é considerável aceitável, conforme ilustrado no diagrama.

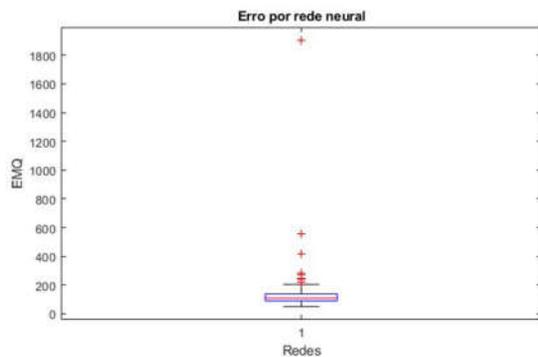


Fig. 13 – Box plot, Simulação-4

6. CONCLUSÕES

Este artigo buscou apresentar a implementação de uma rede neural artificial para a previsão de valores de velocidade de vento, utilizando dados correlacionados envolvendo valores prévios de velocidade do vento, temperatura do ar e radiação global. Conclui-se que a utilização de RNA para este tipo de aplicação é efetiva e que a inserção de variáveis de entrada como radiação global e temperatura do ar impactam na previsão, obtendo os melhores resultados através do uso de temperatura do ar e da radiação juntamente com dados prévios de velocidade de vento separadamente, ou em conjunto. Em outras palavras, as duas variáveis apresentaram resultados correlacionáveis com a variável estocástica de velocidade de vento para períodos curtos, ao invés de dias na previsão.

AGRADECIMENTOS

Os autores deste artigo agradecem ao apoio da FAPEMIG, CNPq, CAPES, INERGE.

REFERÊNCIAS

- Benghanem, M., Mellit, A., & Alamri, S. N. (2009). ANN-based modelling and estimation of daily global solar radiation data: A case study. *Energy conversion and management*, 50(7), 1644-1655.
- Catalão, J. P. D. S., Pousinho, H. M. I., & Mendes, V. M. F. (2011). Short-term wind power forecasting in Portugal by neural networks and wavelet transform. *Renewable energy*, 36(4), 1245-1251.
- Chang, G. W., Lu, H. J., Chang, Y. R., & Lee, Y. D. (2017). An improved neural network-based approach for short-term wind speed and power forecast. *Renewable energy*, 105, 301-311.
- da Silva, T. V., Monteiro, R. V. A., Moura, F. A. M., Albertini, M. R. M. C., Tamashiro, M. A., & Guimaraes, G. C. (2017). Performance Analysis of Neural Network Training Algorithms and Support Vector Machine for Power Generation Forecast of Photovoltaic Panel. *IEEE Latin America Transactions*, 15(6), 1091-1100.
- das Mercedes Machado, R. N., Bezerra, U. H., Pelaes, E. G., de Oliveira, R. C. L., & de Lima Tostes, M. E. (2009). Use of Wavelet Transform and Generalized Regression Neural Network (GRNN) to the Characterization of Short-Duration Voltage Variation in Electric Power System. *IEEE Latin America Transactions*, 7(2), 217-222.
- Doucoure, B., Agbossou, K., & Cardenas, A. (2016). Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. *Renewable Energy*, 92, 202-211.
- Ferro, F., Wazlawick, R., Bastos, R., & Oliveira, C. (2009). Improvement of the short term load forecasting through the similarity among consumption profiles. *IEEE Latin America Transactions*, 7(5), 527-532.
- Guarnieri, R. A., Pereira, E. B., Martins, F. R., & Chan, C. S. (2007, April). Previsões de radiação solar utilizando modelo de Mesoescala: refinamento com redes neurais. In *CBENS-CONGRESSO BRASILEIRO DE ENERGIA SOLAR (Vol. 1)*.
- Hiyama, T., & Kitabayashi, K. (1997). Neural network based estimation of maximum power generation from PV module using environmental information. *IEEE Transactions on Energy Conversion*, 12(3), 241-247.
- Huang, C., Bensoussan, A., Edesess, M., & Tsui, K. L. (2016). Improvement in artificial neural network-based estimation of grid connected photovoltaic power output. *Renewable energy*, 97, 838-848.
- MathWorks (2020). Help Center boxplot. Disponível em: <https://www.mathworks.com/help/stats/boxplot.html?tid=srchtitle>. Acessado em: maio.2020.
- Mellit, A., Sağlam, S., & Kalogirou, S. A. (2013). Artificial neural network-based model for estimating the produced power of a photovoltaic module. *Renewable Energy*, 60, 71-78.
- Mentaschi, L., Besio, G., Cassola, F., & Mazzino, A. (2013). Problems in RMSE-based wave model validations. *Ocean Modelling*, 72, 53-58.
- Olatomiwa, L., Mekhilef, S., Shamsirband, S., Mohammadi, K., Petković, D., & Sudheer, C. (2015). A support vector machine–firefly algorithm-based model for global solar radiation prediction. *Solar Energy*, 115, 632-644.
- Rampinelli, G. A., de Armas Teyra, M. A., Krenzinger, A., & Prieb, C. W. M. (2010). Artificial Intelligence Technics Applied to Analisis of Photovoltaic Energy Systems. *IEEE Latin America Transactions*, 8(5), 512-518.
- Riley, D., & Johnson, J. (2012, June). Photovoltaic prognostics and health management using learning algorithms. In *2012 38th IEEE Photovoltaic Specialists Conference (pp. 001535-001539)*. IEEE.
- Shi, Z., Liang, H., & Dinavahi, V. (2018). Wavelet Neural Network Based Multiobjective Interval Prediction for Short-Term Wind Speed. *IEEE Access*, 6, 63352-63365.
- Simon, H. (1999). *Neural networks: a comprehensive foundation*. Prentice Hall, Inc.
- Theil, H. (1966). Measuring the accuracy of point predictions. *Applied Economic Forecasting*. North Holland Publishing Company. Amsterdam, 15-36.