



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

XXVI SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2022

REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE VELOCIDADE DO VENTO EM ESTAÇÃO EÓLICA NA BAHIA

Lucas Teles de Oliveira¹; Maurício Santana Lordêlo²

1. Bolsista PROBIC/UEFS, Graduando em Agronomia, Universidade Estadual de Feira de Santana, e-mail:

lucastelesdeoliveira3@gmail.com

2. Maurício Santana Lordêlo, Departamento de Ciências Exatas, Universidade Estadual de Feira de Santana, e-mail:

mrlordelo@uefs.br

PALAVRAS-CHAVE: energia renováveis; energia eólica; Redes Neurais Artificiais.

INTRODUÇÃO

O crescimento populacional e o desenvolvimento de novas tecnologias têm feito com que o consumo de energia também cresça. Aliada as crescentes necessidades da população mundial, a demanda por energia vem aumentando cada vez mais, gerando incertezas associadas ao seu fornecimento futuro (Mauad, Ferreira e Trindade, 2017).

A maior parte da energia consumida no mundo é derivada de fontes não renováveis. Já a matriz elétrica brasileira em sua maior parte é renovável, isso devido a predominância das usinas hidrelétricas (EPE). No entanto, em períodos de escassez hídrica, as usinas termelétricas são acionadas para complementar a produção de energia, o que gera principalmente o aumento da emissão de gases de efeito estufa. Diante disso, fontes alternativas de energia renováveis podem ser utilizadas para complementar a produção de energia.

Um exemplo de alternativa energética é a energia eólica, originada por meio da energia cinética contida nas massas de ar em movimento, os ventos. Portanto, para garantir o crescimento da integração de energia renováveis à rede elétrica, é importante a utilização de sistemas avançados de previsão que possam estimar com precisão a geração futura para maior confiabilidade da operação das redes. Segundo Martins, Guarnieri e Pereira (2007) pode-se realizar a previsão de vento para fins de geração eólica em qualquer local utilizando dados disponibilizados por modelos numéricos regionais ou globais.

Carneiro *et al.* (2014) apresentam duas Redes Neurais Artificiais (RNAs) do tipo *Perceptron* com Múltiplas Camadas (PMC) junto com a técnica de *Focused Time Delay Neural Network* (FTNDD), a qual adiciona características dinâmicas à rede por meio de atrasos no tempo, para prever a velocidade do vento.

Bezerra *et al.* (2011) fizeram comparação entre Redes Neurais Recorrentes (NARX), FTDNN e modelos estocásticos (AR, ARMA e ARIMA) para previsão da velocidade do vento.

Utilizando dados de uma estação eólica localizada no município de Irecê, Bahia, este trabalho propõe fazer previsões de velocidade do vento por meio dos algoritmos de RNAs, com o objetivo de avaliar o desempenho de diferentes arquiteturas de rede.

MATERIAL E MÉTODOS

Redes Neurais Artificiais (RNAs) tem como inspiração a estrutura e funcionamento de um sistema nervoso, ou seja, são baseadas no sistema de neurônios biológicos (Faceli *et al.*, 2011).

Uma RNA pode ser composta vários por neurônios, um neurônio é considerado a unidade fundamental processadora de informação. Esses neurônios podem estar dispostos em várias camadas, que geralmente são denominadas de camadas de entrada, onde as informações são apresentadas à rede; camada oculta, onde ocorre o processamento da informação de entrada; e a camada de saída, onde o resultado do processamento é apresentado.

Existem vários tipos de topologia de rede RNAs, no entanto a topologia da rede mais comum é a do tipo *feedforward*, onde a direção com que as informações passam na rede é em um único sentido. A rede *feedforward* multicamadas, também chamadas de *Multilayer Perceptron* (MLP), é a topologia considera padrão. A função de ativação comumente utilizada em RNA é a sigmoide logística e o algoritmo utilizado para ajustar os pesos é denominado de *backpropagation* (Lantz, 2013).

Redes MLP podem ser empregadas para sistemas onde o comportamento varia ao longo do tempo ou são dependentes dele. Uma possível configuração de rede é a MLP com entradas atrasadas no tempo (TDNN – *time delay neural network*) (Silva, Spatti e Flauzino, 2010).

Os dados disponíveis são medições efetuadas entre os anos de 2013 e 2014 por uma estação eólica situada na cidade de Irecê-Ba (11°33'S,41°86'E). Os registros são a cada dez minutos, onde são apresentados os valores da variável velocidade do vento e de outras variáveis registradas pela estação eólica, tendo um total de 52559 observações.

Fez-se o particionamento dos dados com 75% das observações para treino e 25% para teste. Além disso, os valores das variáveis foram normalizados utilizando a normalização linear. Para realizar todo processamento e análise dos dados, utilizou-se o *software* livre R (R Core Team, 2021).

As redes foram implementadas utilizando o pacote *neuralnet* (WRIGHT, 2019), e escolhidas por meio de tentativa e erro. A primeira RNA (nn) foi treinada com quatro variáveis de entrada, temperatura (°C), direção do vento, radiação global (W/m²) e umidade relativa do ar e com 6 neurônios na única camada oculta para prever a velocidade do vento. Já a segunda RNA (nnTD) foi treinada utilizando os dados da velocidade do vento com cinco atrasos de tempo, cinco entradas, e com 6 neurônios na única camada oculta para prever a velocidade do vento.

Para avaliar o desempenho das redes utilizou-se o coeficiente de correlação linear de Pearson (r), raiz quadrada do erro médio quadrático (RMSE) e erro médio absoluto (MAE).

ANÁLISE E DISCUSSÃO DOS RESULTADOS

Na Figura 1, encontram-se os gráficos com as séries das medidas a cada 10 minutos, com a média diária e com a média mensal para a velocidade do vento.

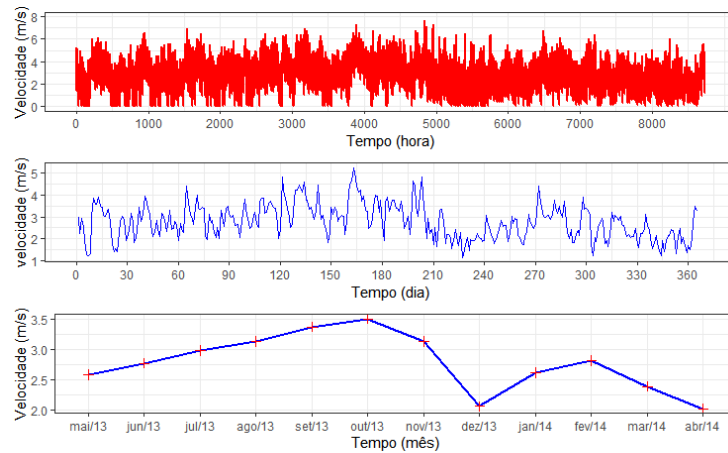


Figura 1 - Série de medidas para a velocidade do vento a cada 10 minutos, com média diária e mensal respectivamente

Na Figura 2 estão representados os valores observados e os valores preditos da velocidade do vento pelas RNAs (nnTD e nn) para o período de teste. Observa-se que a RNA (nnTD) tem um melhor ajuste para os dados de teste do que a RNA (nn), indicando que esse modelo possui um melhor desempenho.

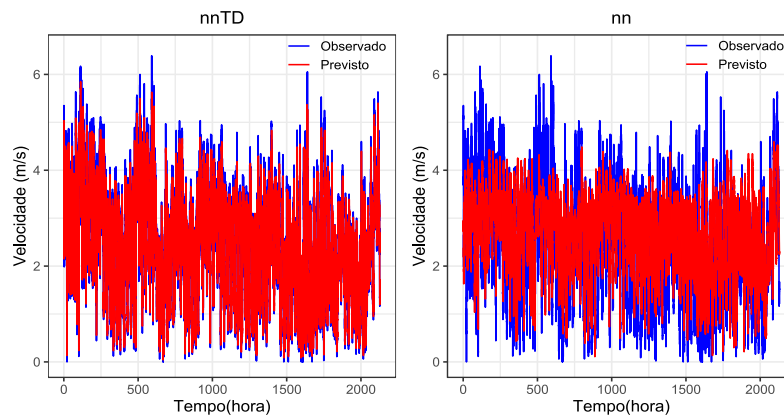


Figura 2 - Dados observados e previsto da velocidade do vento para o conjunto de teste pelas RNAs

Os resultados de previsão obtidos por meio das métricas citadas anteriormente encontra-se na Tabela 1, onde são apresentadas as avaliações para as duas redes analisadas.

Tabela 1 - Avaliações dos modelos de RNAs

RNA	Métricas		
	MAE	RMSE	r
nn	0,7382	0,9214	0,6495
nnTD	0,3040	0,4013	0,9359

O modelo que apresentou melhor desempenho foi utilizando a arquitetura MLP com entradas atrasadas no tempo, a RNA (nnTD). Esse modelo apresentou um menor MAE e

um menor RMSE, onde quanto mais próximo for os seus valores de zero melhor o desempenho, e um coeficiente de correlação com associação linear positiva podendo ser classificado como muito forte.

CONCLUSÕES

O presente trabalho trouxe a abordagem de duas diferentes arquiteturas de redes neurais artificiais para previsão da velocidade do vento, onde pode-se verificar que a rede neural MLP com entradas atrasadas no tempo (TDNN – *time delay neural network*), obteve um bom resultado para a série temporal proposta, podendo assim ser utilizada para a previsão da velocidade do vento, desde que seja levado em consideração os erros calculados para tomada de decisões.

REFERÊNCIAS

- BEZERRA, Erick C. *et al.* Comparação entre modelos estatísticos e redes neurais usando persistência como referência para a previsão da velocidade do vento. *In: SBAI – Simpósio Brasileiro de Automação Inteligente*, 10., 2011, São João del-Rei – MG. Anais[...] São João del-Rei – MG, 2011. p. 369 – 374. Disponível em: <https://fei.edu.br/sbai/SBAI2011/85906.pdf>. Acesso em: 20 jul. 2022.
- CARNEIRO, Tatiane C. *et al.* Redes neurais artificiais para previsão de velocidade do vento: estudo de caso para Maracanaú – CE. *In: CONGRESSO BRASILEIRO DE AUTOMÁTICA*, 20., 2014, Belo Horizonte. Anais[...] Belo Horizonte, 2014. p. 1011-1018. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/12497>. Acesso em: 2 fev. 2022.
- EPE. Matriz Energética e Elétrica. Empresa de Pesquisa Energética. Disponível em: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>. Acesso em: 19 jul. 2022.
- FACELI, K. *et al.* Inteligência artificial: uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011.
- LANTZ, Brett. *Machine Learning with R*. Birmingham - Mumbai: Packt Publishing, 2013.
- MARTINS, F.R.; GUARNIERI, R.A.; PEREIRA, E.B. O aproveitamento da energia eólica. *Revista Brasileira de Ensino de Física*, v. 30, n. 1, 1304, 2007.
- MAUAD, Frederico F.; FERREIRA, Luciana D. C.; TRINDADE, Tatiana C. G. Energia renovável no Brasil: análise das principais fontes energéticas renováveis brasileiras. São Carlos: EESC/USP, 2017. Disponível em: <http://www.livrosabertos.sibi.usp.br/portaldelivrosUSP/catalog/view/168/154/740>. Acesso em: 18 jul. 2022.
- R Core Team. R: A language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing. Disponível em: <https://www.R-project.org/>, 2021
- SILVA, Ivan N. da; SPATTI, Danilo H; FLAUZINO, Rogério A. *Redes neurais artificiais: para engenharia e ciências aplicadas*, Artliber, 2010.
- WRIGHT, M. N. Package ‘neuralnet’ - Training of Neural Networks Disponível em <https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>, 2019.