57º SBPO
SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
Gramado • RS
DE 5 A 9 DE OUTUBRO DE 2025

Aplicação de Redes Neurais do Tipo *Multilayer Perceptron* (MLP) na Previsão da Velocidade do Vento: Um Estudo no interior do Estado de Pernambuco

Maria Luiza Xavier de Holanda Cavalcanti[a], Fábio Sandro dos Santos[b], Luciano Costa[c], Walton Pereira Coutinho[a], Lucimário Gois de Oliveira Silva[a], José Leão[a], Lúcio Camara e Silva[a], Cristiane Perla Sant'Anna[d], Aldsmythys Pinheiro da Costa Cruz[e]

marialuiza.cavalcanti@ufpe.br, fabio.santos@ufpi.edu.br, luciano.costa@academico.ufpb.br, walton.coutinho@ufpe.br, lucimario.silva@ufpe.br, ze.leao@ufpe.br, lucio.silva@ufpe.br, cristiane.perla@ufpe.br, aldsmythys@gmail.com

[a]Programa de Pós-Graduação em Engenharia de Produção – PPGEP/CAA, Universidade Federal de Pernambuco (UFPE)
Avenida Marielle Franco, s/n, Bairro Nova Caruaru, Caruaru – PE, 55014-900, Brasil
[b]Universidade Federal do Piauí (UFPI)
[c]Departamento de Engenharia de Produção (DEP), LOG-UFPB – Universidade Federal da Paraíba (UFPB)
Campus Universitário de João Pessoa – Campus I – Conj. Pres. Castelo Branco III, João Pessoa – PB, 58051-970, Brasil
[d]Companhia Hidro Elétrica do São Francisco (Chesf)
[e]Operador Nacional do Sistema Elétrico (ONS)

RESUMO

Este estudo aplica Redes Neurais Artificiais do tipo MLP para prever a velocidade do vento em estações meteorológicas de Pernambuco, utilizando 15 variáveis atmosféricas obtidas por meio do INMET. A abordagem autoregressiva iterativa realiza previsões de curto prazo com horizonte de 24 horas. O desempenho foi avaliado por métricas de erro (MAE, RMSE, MAPE), mostrando bom desempenho em regiões com padrões de vento estáveis.

PALAVRAS CHAVE. Previsão de Velocidade do Vento. Inteligencia Artificial. Redes Neurais Artificiais. *Multilayer Perceptron* (MLP). Energia Eólica em Pernambuco.

Tópicos: EN&OG – PO na Área de Energia, Óleo e Gás; EST&AM – PO Analytics em Estatística e Aprendizado de Máquina; IA – PO e IA

ABSTRACT

This study applies MLP-type Artificial Neural Networks to predict wind speed at meteorological stations in Pernambuco, using 15 atmospheric variables obtained through INMET. The iterative autoregressive approach performs short-term forecasts with a 24-hour horizon. The performance was evaluated by error metrics (MAE, RMSE, MAPE), showing good performance in regions with stable wind patterns.

KEYWORDS. Wind Speed Forecasting. Artificial Intelligence. Artificial Neural Networks. Multilayer Perceptron (MLP). Wind Energy in Pernambuco.

Topics: EN&OG – OR in Energy Area, Oil and Gas; ST&ML – OR Analytics in Statistics and Machine Learning; AI – OR and AI

https://proceedings.science/p/212129?lang=pt-br

1. Introdução

Nos últimos anos, a crescente demanda por fontes de energia limpa tem impulsionado o desenvolvimento de estudos sobre a dinâmica atmosférica, com destaque para a energia eólica no Brasil, especialmente na região Nordeste, que concentra mais de 80% da capacidade instalada nacional [Vidal et al., 2024]. Na 28^a Conferência das Partes da Convenção-Quadro das Nações Unidas sobre Mudanças Climáticas (COP28), líderes globais reafirmaram o compromisso de triplicar a capacidade mundial de geração por fontes renováveis até 2030, com o objetivo de limitar o aumento da temperatura global a menos de 1,5°C [Agency, 2024].

A previsão precisa da velocidade do vento é essencial para o planejamento energético e a operação de sistemas que dependem de condições atmosféricas [Zhao et al., 2020]. No entanto, a variabilidade espacial e temporal dos fenômenos meteorológicos impõe desafios à modelagem, tornando métodos tradicionais, como o ARIMA (*Autoregressive Integrated Moving Average*), menos eficazes em cenários com alta instabilidade [Haes Alhelou et al., 2019]. Diante disso, técnicas baseadas em Inteligência Artificial (IA), como as Redes Neurais Artificiais (RNAs), vêm se destacando por sua capacidade de capturar padrões não lineares em séries temporais [Zhang et al., 2019].

Este trabalho propõe a aplicação de uma rede neural do tipo *Multilayer Perceptron* (MLP) para prever a velocidade do vento em estações meteorológicas no estado de Pernambuco, com foco especial na estação de Petrolina, que apresentou os melhores indicadores de desempenho em análises preliminares. Um dos principais diferenciais desta abordagem é a utilização de quinze variáveis meteorológicas como entradas do modelo, ampliando a capacidade de representação das condições atmosféricas e permitindo capturar com maior precisão os padrões que influenciam a velocidade do vento. Para isso, utilizam-se dados históricos disponibilizados pelo Instituto Nacional de Meteorologia (INMET), que servem de base para avaliar a acurácia das previsões com horizonte de 24 horas, por meio de métricas consagradas de erro. O objetivo é contribuir para o aprimoramento de sistemas preditivos aplicados ao planejamento energético regional.

2. Metodologia

2.1. Seleção e Normalização das Variáveis

Este estudo se destaca pela utilização de quinze variáveis meteorológicas como entradas, buscando captar de forma ampla os fatores que influenciam a dinâmica do vento. As variáveis, selecionadas com base na literatura [Fleck et al., 2016; Zhang et al., 2019], foram convertidas para formato numérico e normalizadas entre 0 e 1 usando a técnica de *Min-Max Scaling* para reduzir o impacto de magnitudes diferentes. O processo completo de preparação dos dados, treinamento e previsão está detalhado no Algoritmo 1.

Tabela 1: Variáveis meteorológicas utilizadas no modelo e justificativas

Símbolo	Variável	Justificativa
x_1, x_2	Temperatura do ar (máx, mín)	Influencia a densidade do ar e o desempenho da turbina
x_3–x_5	Umidade relativa (inst, máx, mín)	Pode alterar o comportamento do vento e impactar pás eólicas
x_6–x_8	Ponto de orvalho (inst, máx, mín)	Indica potencial de condensação, afetando turbinas
x_9–x_{11}	Pressão atmosférica (inst, máx, mín)	Relaciona-se à densidade do ar e eficiência de conversão eólica
x_{12}	Rajadas de vento	Relacionadas a flutuações abruptas na geração
x_{13}	Radiação solar	Importante em cenários híbridos (eólico-solar)
x_{14}	Precipitação	Afeta confiabilidade e desgaste de componentes
x_{15}	Velocidade atual do vento	Usada como entrada autoregressiva

2.2. Arquitetura do Modelo

Utiliza-se uma rede neural MLP (*Multilayer Perceptron*), do tipo *feedforward*, composta por camada de entrada, uma ou mais camadas ocultas e uma de saída, sem conexões recorrentes [Haykin, 2009]. Cada neurônio calcula uma soma ponderada das ativações da camada anterior, seguida por uma função de ativação:

$$z_j^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_{ij}^{(l)} a_i^{(l-1)} + b_j^{(l)}, \quad a_j^{(l)} = f\left(z_j^{(l)}\right) \tag{1}$$

onde $w_{ij}^{(l)}$ é o peso da conexão, $a_i^{(l-1)}$ a ativação anterior e $b_j^{(l)}$ o viés. Nas camadas ocultas, aplica-se a função sigmoide logística:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{2}$$

Essa função introduz não linearidade e possui derivada contínua, favorecendo a otimização. A saída usa ativação linear $f(x) = x$, apropriada para regressão. A rede é treinada via retropropagação com gradiente descendente, minimizando a função de custo MSE (*Mean Squared Error*):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2 \tag{3}$$

em que y_i é o valor observado, $\hat{y}_i$ o previsto, e n o número de amostras. O treinamento é interrompido por critério de erro ou iteração máxima. A arquitetura e hiperparâmetros foram definidos por experimentação preliminar conforme trabalhos anteriores [Fleck et al., 2016].

2.3. Métricas de Avaliação

Para avaliar o desempenho do modelo, foram utilizadas três métricas amplamente empregadas em previsão de séries temporais:

Tabela 2: Métricas estatísticas para avaliação do modelo

Métrica	Fórmula	Interpretação	Referência
MAE	$\text{MAE} = \frac{1}{n}\sum \lvert y_i - \hat{y}_i \rvert$	≤ 1 m/s (bom ajuste)	Willmott e Matsuura [2005]
RMSE	$\text{RMSE} = \sqrt{\frac{1}{n}\sum (y_i - \hat{y}_i)^2}$	$\leq 1{,}5$ m/s (aceitável)	Chai e Draxler [2014]
MAPE	$\text{MAPE} = \frac{100\%}{n}\sum \left\lvert \frac{y_i - \hat{y}_i}{y_i} \right\rvert$	$\leq 10\%$ (excelente)	Hyndman e Koehler [2006]

2.4. Previsão Autoregressiva de Curto Prazo com MLP

A previsão da velocidade do vento foi realizada para um horizonte de 24 horas por meio de uma abordagem autoregressiva. Nesse método, a saída prevista para o instante $t+1$ é reutilizada como entrada para estimar o instante seguinte $t+2$, e assim sucessivamente, até completar os 24 passos. Apenas a variável-alvo (velocidade do vento) é atualizada a cada iteração, enquanto as demais variáveis meteorológicas são mantidas constantes, representando um cenário operacional com atualizações limitadas em tempo real [Zhang et al., 1998].

A rede neural utilizada segue a arquitetura descrita anteriormente, com estrutura *feed-forward*, duas camadas ocultas e as respectivas funções de ativação adequadas para a tarefa de regressão. O desempenho do modelo foi avaliado conforme as métricas previamente mencionadas, complementado por análise gráfica da série temporal prevista. O fluxo completo, desde o pré-processamento até a geração das previsões, está descrito no Algoritmo 1.

Algorithm 1: Fluxo de treinamento e previsão com MLP (versão resumida)

Input: CSV com dados meteorológicos
Output: Modelo MLP treinado e previsões de 24h

1 Carregar bibliotecas e importar dados; converter e tratar dados (NA $\rightarrow$ remoção ou 0); normalizar variáveis (Min-Max [0,1]);
2 Separar base (80% treino, 20% teste); definir fórmula: alvo $\sim$ variáveis; treinar MLP (15-10-5-1); avaliar (MAE, MAPE, RMSE); plotar gráficos (`ggplot2`);
3 **Previsão Autoregressiva (24h):** usar última observação, prever iterativamente, atualizar entrada e manter variáveis fixas; desnormalizar e plotar previsão final.

https://proceedings.science/p/212129?lang=pt-br

3. Resultados

O modelo MLP apresentou desempenho consistente na previsão de 24 horas para Petrolina, com resultados que indicam boa precisão e estabilidade. A Tabela 3 apresenta as métricas utilizadas para avaliar o modelo. O valor de MAE demonstra um erro absoluto médio baixo, enquanto o RMSE, que penaliza maiores erros, permanece em um nível aceitável. O MAPE indica que o erro percentual médio é inferior a 20%, corroborando a adequação do modelo para previsões de curto prazo. Embora o erro aumente ao longo do horizonte devido à abordagem autoregressiva, o modelo se mostrou robusto para aplicações operacionais locais.

Tabela 3: Desempenho da previsão autoregressiva para horizonte de 24 horas para Petrolina - PE

Métrica	Valor	Referência
MAE	0,4579	≤ 1 (bom ajuste)
RMSE	0,5796	$\leq 1{,}5$ (aceitável)
MAPE	14,91%	$\leq 20\%$ (aceitável)

4. Conclusão

Este trabalho aplicou redes MLP para previsão de curto prazo da velocidade do vento em Pernambuco, utilizando abordagem autoregressiva com horizonte de 24 horas. O modelo apresentou desempenho satisfatório,validado por métricas como MAE, RMSE e MAPE. Como pesquisas futuras, propõe-se: (i) utilização de dados medidos em maiores altitudes, mais representativos para fins energéticos; (ii) aplicação do modelo em regiões com diferentes perfis meteorológicos. Tais avanços podem tornar o modelo mais robusto e aplicável a outros cenários reais de previsão eólica.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio institucional prestado durante a realização deste trabalho.

Referências

Agency, I. E. (2024). Cop28 tripling renewable capacity pledge. URL `https://www.iea.org/reports/cop28-tripling-renewable-capacity-pledge`. Accessed: March 1, 2024.

Chai, T. e Draxler, R. R. (2014). Root mean square error (rmse) or mean absolute error (mae)? arguments against avoiding rmse in the literature. *Geoscientific Model Development*, 7(3).

Fleck, L., Tavares, M. H. F., Eyng, E., Helmann, A. C., e Andrade, M. A. d. M. (2016). Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*.

Haes Alhelou, H., Hamedani-Golshan, M. E., Njenda, T. C., e Siano, P. (2019). A survey on power system blackout and cascading events: Research motivations and challenges. *Energies*, 12(4).

Haykin, S. (2009). *Neural Networks and Learning Machines*. Prentice Hall, 3rd edition.

Hyndman, R. J. e Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4):679–688.

Vidal, D. B. et al. (2024). *Avaliação do potencial de geração de energia eólica offshore no litoral do Nordeste brasileiro*. PhD thesis, Universidade Federal da Bahia.

Willmott, C. J. e Matsuura, K. (2005). Advantages of the mean absolute error over the root mean squared error for evaluating model performance. *Climate Research*, 30(1):79–82.

Zhang, G. P., Eddy Patuwo, B., e Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1):35–62.

Zhang, J. et al. (2019). Wind speed forecasting based on neural networks with feature engineering. *Applied Energy*.

Zhao, S., Blaabjerg, F., e Wang, H. (2020). An overview of artificial intelligence applications for power electronics. *IEEE Transactions on Power Electronics*, 36(4):4633–4658.