

REVISÃO SISTEMÁTICA DO USO DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÕES DE VELOCIDADE DO VENTO NO NORDESTE DO BRASIL

1 INTRODUÇÃO

A produção eólica vem crescendo ao longo dos anos, no Brasil, por exemplo, o país atingiu 4,8 GW de nova capacidade instalada e mais de 1000 parques eólicos em operação ultrapassando 30 GW de instalação no total, no ano de 2023 (GWEC, 2024). Considerando a relevância do setor eólico e tendo em vista os impactos que as mudanças climáticas podem causar nas fontes de energia renovável, é indispensável antecipar o desempenho futuro na geração de energia por meio desses recursos. Geralmente, a previsão da capacidade de produção energética se faz analisando as tendências e a sazonalidades dos componentes climáticos a partir de suas séries temporais. Dado o avanço da inteligência artificial (IA) é oportuno aplicar suas técnicas visando alcançar resultados mais precisos.

A inteligência artificial é uma técnica computacional avançada em que simulam características humanas na resolução de problemas e na aprendizagem. A aplicação de IA pode ser útil em diversas aplicações (Olabi et al., 2023; Ramos et al., 2024). Inúmeros métodos são exemplificados na literatura e podem ser aplicados na previsão da velocidade e densidade dos ventos. As Redes Neurais Artificiais (RNA) trabalham satisfatoriamente na aprendizagem e na generalização de padrões, podendo ser aplicadas no reconhecimento de padrões,

As Redes Neurais Artificiais (RNA), as quais trabalham satisfatoriamente na aprendizagem e na generalização de padrões podendo ser aplicadas em reconhecimento de padrões, por exemplo (Zucатели et al., 2021; Camelo et al., 2018a; Camelo et al., 2018b) e a Long Short Term Memory (LSTM) a qual é uma arquitetura de rede neural que emprega a sequência de dados e atua de forma eficiente na previsão a longo prazo (Nascimento, Melo e Moreira, 2023; Silva et al., 2022; Neto Mattos et al., 2021; Neto Mattos et al., 2020; Padilha et al., 2022) são exemplos relevantes. Além disso, pode-se citar a Rede Neural Recorrente (RNN) que se mostra eficiente em tarefas que envolvam sequência de dados temporais ou sequências (Zucатели et al., 2020), por sua vez, o *k-Nearest Neighbor* (KNN) é um algoritmo de aprendizado de máquina que classifica um novo ponto a partir dos pontos de dados mais próximos é um algoritmo de aprendizagem de máquina que executa uma classificação de um novo ponto a partir dos pontos de dados mais próximo (KNN) (Silva et al., 2021; Ribeiro et al., 2022) e realiza a clusterização, agrupando os dados mais semelhantes entre si e a clusterização em que se agrupa os dados mais semelhantes entre si (Ribeiro et al., 2023).

Considerando o exposto, o presente estudo tem como finalidade conduzir uma revisão bibliométrica a respeito da aplicação de técnicas de Inteligência Artificial na previsão da velocidade do vento. Esta abordagem é essencial, dada a importância da energia eólica como fonte energética na região, acentuando a necessidade de métodos eficazes e precisos para antecipar padrões de vento. Além do mais, procura-se evidenciar possíveis lacunas no conhecimento existente e oportunidades de aprimorar ainda mais a aplicação de IA nesse contexto.

2 METODOLOGIA

O presente estudo tomou como base a metodologia proposta por Tranfield, Denyer e Smart (2003) aplicando uma nova perspectiva. Tranfield, Denyer e Smart, 2003 adotaram as seguintes etapas: (I) de plano de revisão, (II) condução da pesquisa e (III) relatório e divulgação.

Com o propósito de selecionar um conjunto relevante de estudos a respeito da aplicação de inteligência artificial nas projeções de ventos na região Nordeste do Brasil utilizou-se três bancos de dados, o *Web of Science* Coleção Principal (*Clarivate Analytics*), *Science Direct* e

Scopus. A pesquisa foi realizada em três etapas em que as palavras-chaves foram separadas pelo conectivo AND.

A pesquisa foi dividida em três partes, a fim de abranger um maior número de estudos. A primeira etapa da pesquisa foi conduzida aplicando as seguintes palavras-chave: "*artificial intelligence**" AND "*neural network**" AND "*time serie**" AND "*climat* change**" AND "*wind **" AND "*Brazil*" nos bancos de dados *Web of Science* e *Scopus*. Em seguida, a fim de refinar a pesquisa e buscar estudos mais direcionados ao Nordeste do Brasil aplicou-se as seguintes palavras-chave: "*artificial intelligence**" AND "*neural network**" AND "*wind **" AND "*Brazil*" AND "*Northeast **". Por fim, a pesquisa resultou apenas em 2 estudos, um encontrado na *Web of Science* e outro *Scopus*. Por fim, 21 estudos relacionando a aplicação de técnicas de inteligência artificial na região Nordeste do Brasil foram selecionados e analisados.

3 RESULTADO E DISCUSSÃO

Os estudos analisados foram publicados entre os anos de 2017 a 2023. Observa-se uma variabilidade no número de publicações nos anos estudados, sendo os anos de 2018 e 2020 aqueles que apresentaram o maior número de artigos publicados o que representa 23,8% das amostras. Ao agrupar as publicações em dois períodos observa-se que entre 2017-2020 foram publicados 57,1% dos estudos da amostra e entre 2021-2023 esse resultado foi de 42,9%, nesse período, em cada ano foram publicados 3 estudos, o que representa 14,3% da amostra.

Os quatro periódicos com o maior número de publicações foram a *Energy*, com fator de impacto de 9.0 e 4 publicações, a Revista Brasileira de Meteorologia, com fator de impacto de 0.556 e 3 estudos publicados, a *International Journal of Electrical Power & Energy Systems*, com fator de impacto de 5.2 e a *Energies* com fator de impacto de 3.52 e ambas com duas publicações cada. As revistas em que se observou o maior número de publicações representam juntas 52,4% da amostra. Os outros 10 periódicos publicaram apenas um estudo cada e juntos representam 47,6% dos estudos.

As métricas de avaliação são compreendidas como medidas quantitativas aplicadas para analisar o desempenho e a eficácia de modelos de aprendizagem e algoritmos. As principais métricas aplicadas nos estudos foram Erro Médio Absoluto (MAE), aplicado em 15 estudos, Erro Percentual Médio Absoluto (MAPE) em 13 artigos, a Raiz do Erro Quadrático Médio (RMSE) aplicada em 12 estudos e o Erro Quadrático Médio (MSE) em 8 trabalhos.

O MAE, equação 1, mede o valor médio do erro absoluto entre as séries observadas e ajustadas (Camelo *et al.*, 2018a; Camelo *et al.* 2018b). O MAPE, equação 2, além de não ser sensível a escala, produz um erro percentual em relação ao desempenho dos modelos que facilita seu entendimento. O RMSE, equação 3, representa as diferenças quadráticas individuais entre as séries temporais observadas e ajustadas. Valor alto, a margem de erro nas variáveis ajustadas é alta e valores próximos a zero, indica um ajuste quase perfeito. No MSE, equação 4, os menores valores evidenciam um alto desempenho dos valores previstos, no entanto, é sensível à escala (Khosravi, Machado e Nunes, 2018; Neto Mattos *et al.*, 2020).

As técnicas de inteligência artificial são relevantes na identificação de padrões complexos, além de ser capazes de aprender o desempenho de dados ao longo do tempo sem a necessidade de interferência humana constante. Essas técnicas podem ser aplicadas em amplos problemas relacionados a inteligência artificial, como por exemplo, em processamento de dados e aprendizagem de máquina.

Os estudos analisados empregaram uma variedade de técnicas de Inteligência Artificial (IA). Algumas dessas técnicas estão diretamente associadas à IA, enquanto outras são também utilizadas em aprendizado de máquina, processamento de dados, análise de dados, estatística.

Nos estudos analisados as técnicas mais aplicadas foram as seguintes: Redes Neurais Artificiais (RNAs) utilizadas em 8 estudos, Redes *Long Short-Term Memory* (LSTM), aplicada

em 4 estudos e *k-nearest-neighbors* (KNN) assim como o SVR com *kernel* linear foram empregados em 3 estudos cada. Sendo as duas primeiras técnicas associadas diretamente a Inteligência Artificial e as duas últimas, utilizadas em diversos domínios, como por exemplo, aprendizado de máquina, estatística e análise de dados.

As RNAs foram inspiradas nos neurônios humanos, ou seja, são redes computacionais baseadas nas redes neurais biológicas do cérebro humano. Desta forma, possuem a capacidade de aprendizagem, de reconhecer padrões e fazer generalizações levando em consideração o acúmulo de conhecimento (Kalhor et al., 2016; Camelo et al., 2018). As RNAs estão organizadas em camadas em que os preditores foram a camada superior enquanto as previsões, a camada superior. Essas camadas também podem ser compreendidas como a entrada e a saída, respectivamente (Camelo et al., 2018). *Perceptron* multicamadas (MLP) é a estrutura mais comum de uma RNA. Além das camadas de entrada e saída também possuem camadas ocultas (Kalhor et al., 2016).

O LSTM é uma rede neural recorrente que apresentam uma evolução e uma melhoria significativas na capacidade de modelar padrões climáticos sequencias complexos. Elaborado para trabalhar com amostras que variam no tempo, sendo apto na aprendizagem de dependências apresentadas ao longo do tempo. Outro ponto positivo, refere-se ao fato de capturarem e reterem informações durante longos períodos de tempo e evita o desaparecimento de gradientes, demonstrando melhoria em relação as redes neurais recorrentes convencionais. Além disso, é eficaz na previsão de padrões temporais e é capaz de descobrir relações ocultas e não lineares entre as variáveis climáticas (De Paula et al., 2023; Hong, Rioflorida e Zhang, 2024; Poecke, Tabari e Hellinckx, 2024; Peiqi et al., 2024)

Na arquitetura da célula LSTM existem dois componentes, o estado oculto e o estado interno. O primeiro relaciona-se com a memória de curto prazo e o segundo, a memória de longo prazo (Hewamalage, Bergmeir e Bandara, 2021). A LSTM é composta por entradas e de saídas, portas de esquecimento e células de memória. A partir de suas portas e unidades de memória, encarregam-se de ler, salvar, redefinir e atualizar os dados históricos de longa distância (Peiqi et al., 2024).

Por sua vez, o KNN é um método útil de regressão o qual pode ser aplicado a variados conjuntos de dados. É uma abordagem simples a qual leva em consideração os números vizinhos mais próximos para realizar a estimativa (Alanazi et al., 2023; Huwaimel et al., 2023). Por fim, o SVR com *kernel* linear é um algoritmo que utiliza hiperplanos para realizar previsões numéricas. A utilização do SVR com o *kernel* linear é mais computacionalmente eficiente e reduz a susceptibilidade a *outliers* (Da Silva et al., 2021; Da Silva et al., 2022).

4 CONCLUSÃO

Foram investigados 21 estudos os quais aplicaram técnicas de inteligência artificial em projeções de ventos para a região Nordeste do Brasil. Os estudos analisados foram publicados entre 2017 e 2023, nota-se que houve uma variação entre os anos em que em a maior parte dos estudos da amostra foram publicados nos anos de 2018 e 2020.

Evidenciou-se uma variabilidade de periódicos em que os estudos foram publicados, majoritariamente, foi encontrado um estudo em cada periódico, com exceção, dos periódicos *Energy*, *International Journal of Electrical Power and Energy Systems*, *Energies* e Revista Brasileira de Meteorologia.

Os estudos aplicaram múltiplos métodos de avaliação, a maior parte dos estudos optou por utilizar pelo menos dois. Os principais métodos utilizados foram o MAE, o MAPE, o RMSE e o MSE. As técnicas aplicadas também foram bastante diversificadas, não obstante, a RNAs, utilizada em 8 estudos; a LSTM, em 4 artigos e o *k-Nearest-Neighbors* e o SVR com *kernel* linear em 3 trabalhos cada.

Por fim, a aplicação de técnicas de inteligência artificial na previsão de ventos representa um avanço importante na gestão eficiente desse recurso. A evolução na capacidade de previsão desse recurso pode contribuir para um planejamento energético eficaz.

AGRADECIMENTOS

Os autores agradecem o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), bolsa 167824/2022-8 e a Fundação de Apoio à Pesquisa do Estado da Paraíba Project 16/2022.

REFERÊNCIAS

- ALANAZI, J *et al.* Application of different mathematical models based on artificial intelligence technique to predict the concentration distribution of solute through a polymeric membrane. **Ecotoxicology and Environmental Safety**, v. 262, p. 115183, 2023. DOI: <https://doi.org/10.1016/j.ecoenv.2023.115183>
- CAMELO, H DO N *et al.* A hybrid model based on time series models and neural network for forecasting wind speed in the Brazilian northeast region. **Sustainable Energy Technologies and Assessments**, v. 28, p. 65-72, 2018a. DOI: <https://doi.org/10.1016/j.seta.2018.06.009>
- CAMELO, H DE N *et al.* Proposal for Prediction of Wind Speed through Hybrid Modeling Elaborated from ARIMAX and ANN Models. **Revista Brasileira de Meteorologia**, v. 33(1), p. 115-129, 2018b. DOI: <http://dx.doi.org/10.1590/0102-7786331005>
- DE PAULA, M *et al.* Predicting Energy Generation in Large Wind Farms: A Data-Driven Study with Open Data and Machine Learning. **Inventions**, v. 8, p. 126, 2023. DOI: <https://doi.org/10.3390/inventions8050126>
- GWEC - GLOBAL WIND REPORT 2024, 2024. Disponível em: https://gwec.net/wp-content/uploads/2024/04/GWR-2024_digital-version_final-1.pdf Acesso em: 13 de agosto de 2025.
- HEWAMALAGE, H.; BERGMEIR, C.; BANDARA, K. Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. **International Journal of Forecasting**, v. 37(1), p. 388-427, 2021. DOI: <https://doi.org/10.1016/j.ijforecast.2020.06.008>.
- HUWAIMEL, B *et al.* Computational estimation of drug's concentration distribution through a microporous membrane using artificial intelligence approach. **Journal of Molecular Liquids**, v. 380, p. 121691, 2023. DOI: <https://doi.org/10.1016/j.molliq.2023.121691>
- HONG, Y.; RIOFLORIDO, C. L. P. P.; ZHANG, W. Hybrid deep learning and quantum-inspired neural network for day-ahead spatiotemporal wind speed forecasting. **Expert Systems with Applications**, v.241(1), p.122645, 2024. DOI: <https://doi.org/10.1016/j.eswa.2023.122645>.
- KALHOR, T *et al.* Modeling of energy ratio index in broiler production units using artificial neural networks. **Sustainable Energy Technologies and Assessments**, v. 17, p. 50-55, 2016. DOI: <https://doi.org/10.1016/j.seta.2016.09.002>.
- KHOSRAVI, A.; MACHADO, L.; NUNES, R. O. Time-series prediction of wind speed using machine learning algorithms: A case study Osorio wind farm, Brazil. **Applied Energy**, v.224, p. 550-566, 2018. DOI: <https://doi.org/10.1016/j.apenergy.2018.05.043>
- NASCIMENTO, E. G. S.; MELO, T. A. C DE., MOREIRA, D. M. A transformer-based deep neural network with wavelet transform for forecasting wind speed and wind energy. **Energy**, v. 278, p. 127678, 2023. DOI: <https://doi.org/10.1016/j.energy.2023.127678>.
- NETTO MATTOS, P. S. G de *et al.* A Hybrid Nonlinear Combination System for Monthly Wind Speed Forecasting. **IEEE Access**, v. 18, 2020. DOI: 10.1109/ACCESS.2020.3032070

OLABI, A. G et al. Application of artificial intelligence for prediction, optimization, and control of thermal energy storage systems. *Thermal Science and Engineering Progress*, v. 39, p.101730, 2023. DOI: <https://doi.org/10.1016/j.tsep.2023.101730>.

PADILHA, G. A. G et al. Transformer-Based Hybrid Forecasting Model for Multivariate Renewable Energy. *Applied Sciences*, v. 12, p. 10985, 2022. DOI: <https://doi.org/10.3390/app122110985>

POECKE, A. V.; Tabari, H.; Hellinckx, P. Unveiling the backbone of the renewable energy forecasting process: Exploring direct and indirect methods and their applications. **Energy Reports**, v.11, p.544-557, 2024. DOI: <https://doi.org/10.1016/j.egy.2023.12.031>

PEIQI, S *et al.* Interval forecasting for wind speed using a combination model based on multiobjective artificial hummingbird algorithm. **Applied Soft Computing**, v. 150, p. 111090, 2024. DOI: <https://doi.org/10.1016/j.asoc.2023.111090>.

RAMOS, A et al. Artificial intelligence and machine learning applications in the Spanish nuclear field. *Nuclear Engineering and Design*, v. 147, p. 112842, 2024. DOI: <https://doi.org/10.1016/j.nucengdes.2023.112842>.

RIBEIRO, M. H. D. M et al. Efficient bootstrap stacking ensemble learning model applied to wind power generation forecasting. *International Journal of Electrical Power and Energy Systems*, v. 136, p. 107712, 2022. DOI: <https://doi.org/10.1016/j.ijepes.2021.107712>

RIBEIRO, R.; FANZERES, B. Identifying Representative Days of Solar Irradiance and Wind Speed in Brazil using Machine Learning Techniques. *Energy and AI*, v. 9, 2023. DOI: <https://doi.org/10.1016/j.egyai.2023.100320>

SILVA, R. G da et al. A novel decomposition-ensemble learning framework for multi-step ahead wind energy forecasting. *Energy*, v. 216, p. 119174, 2021. DOI: <https://doi.org/10.1016/j.energy.2020.119174>

SILVA, R. G da *et al.* Multi-step short-term wind speed forecasting based on multi-stage decomposition coupled with stacking-ensemble learning approach. *International Journal of Electrical Power and Energy Systems*, v. 143, p.108504, 2022. DOI: <https://doi.org/10.1016/j.ijepes.2022.108504>

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. *British Journal of Management*, v. 14, p. 207–222, 2003. DOI: <https://onlinelibrary.wiley.com/doi/10.1111/1467-8551.00375>

ZUCATELLI, P. J et al. Nowcasting prediction of wind speed using computational intelligence and wavelet in Brazil. *International Journal for Computational Methods in Engineering Science and Mechanics*, v. 21(6), p. 343-369, 2020. DOI: <https://doi.org/10.1080/15502287.2020.1841335>

ZUCATELLI, P. J et al. An investigation on deep learning and wavelet transform to nowcast wind power and wind power ramp: A case study in Brazil and Uruguay. *Energy*, v. 230, p.120842, 2021. DOI: <https://doi.org/10.1016/j.energy.2021.120842>