RCMOS – Revista Científica Multidisciplinar O
Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 15/08/2026 | aceito: 18/08/2026 | publicação: 21/08/2026

Técnicas de inteligência artificial para a modelagem do comportamento do vento: inovações na previsão eólica

Artificial intelligence techniques for modeling wind behavior: innovations in wind forecasting
Técnicas de inteligencia artificial para modelar el comportamiento del viento: innovaciones en el pronóstico eólico

Lucas Emanuel Almeida Barboza

Resumo:
A natureza estocástica e caótica do vento representa um dos maiores desafios para a integração segura da energia eólica às redes elétricas modernas. O presente artigo apresenta uma revisão bibliográfica qualitativa com o objetivo de analisar a aplicação de técnicas de Inteligência Artificial (IA) e Aprendizado de Máquina (Machine Learning) na modelagem e previsão do comportamento do vento. A metodologia fundamenta-se em uma revisão integrativa da literatura, selecionando artigos recentes e obras de referência sobre ciências de dados aplicadas a energias renováveis. Os resultados indicam que modelos tradicionais físicos e estatísticos apresentam limitações em horizontes de curtíssimo prazo, cenário onde as Redes Neurais Artificiais (RNAs) e algoritmos de Deep Learning se destacam pela capacidade de mapear padrões não lineares complexos. Conclui-se que a adoção sistêmica da IA não apenas reduz os erros de previsão (minimizando penalidades regulatórias), mas também impulsiona a digitalização do setor por meio de tecnologias preditivas avançadas.

Palavras-chave:
Inteligência artificial. Machine Learning. Previsão eólica. Redes neurais artificiais. Séries temporais.

Abstract:
The stochastic and chaotic nature of wind is one of the greatest challenges to safely integrating wind energy into modern power grids. This article presents a qualitative literature review aimed at analyzing the application of artificial-intelligence (AI) and machine-learning techniques to modeling and forecasting wind behavior. The methodology is based on an integrative literature review selecting recent articles and reference works on data science applied to renewable energy. The results indicate that traditional physical and statistical models have limitations over very short time horizons, a setting in which artificial neural networks (ANNs) and deep-learning algorithms stand out for their ability to map complex nonlinear patterns. It is concluded that the systemic adoption of AI not only reduces forecasting errors and minimizes regulatory penalties but also drives sector digitalization through advanced predictive technologies.

Keywords:
Artificial intelligence. Machine learning. Wind forecasting. Artificial neural networks. Time series.

Resumen:
La naturaleza estocástica y caótica del viento representa uno de los mayores desafíos para integrar de forma segura la energía eólica en las redes eléctricas modernas. Este artículo presenta una revisión bibliográfica cualitativa cuyo objetivo es analizar la aplicación de técnicas de inteligencia artificial (IA) y aprendizaje automático (Machine Learning) al modelado y pronóstico del comportamiento del viento. La metodología se fundamenta en una revisión integradora de la literatura que selecciona artículos recientes y obras de referencia sobre ciencia de datos aplicada a energías renovables. Los resultados indican que los modelos físicos y

RCMOS – Revista Científica Multidisciplinar O
Saber. ISSN: 2675-9128. São Paulo - SP.
Ano VII, v.1 2026 | submissão: 15/08/2026 | aceito: 18/08/2026 | publicação: 21/08/2026

estadísticos tradicionales presentan limitaciones en horizontes de muy corto plazo, contexto en el que las redes neuronales artificiales (RNA) y los algoritmos de Deep Learning destacan por su capacidad para mapear patrones no lineales complejos. Se concluye que la adopción sistémica de la IA no solo reduce los errores de pronóstico y minimiza penalizaciones regulatorias, sino que también impulsa la digitalización del sector mediante tecnologías predictivas avanzadas.

Palabras clave:
Inteligencia artificial. Machine Learning. Pronóstico eólico. Redes neuronales artificiales. Series temporales.

1. Introdução

A crescente penetração da energia eólica nas matrizes energéticas globais traz consigo um desafio operacional significativo: a intermitência. A impossibilidade de despachar a energia eólica sob demanda exige previsões meteorológicas e de geração altamente precisas para que os Operadores Nacionais do Sistema (ONS) possam balancear a rede elétrica, acionando ou desligando outras fontes de energia em tempo real (SOMAN et al., 2010). Historicamente, a previsão eólica tem se apoiado em Modelos de Previsão Numérica de Tempo (NWP) de mesoescala e métodos estatísticos tradicionais, como o ARIMA. Contudo, a complexidade fluidodinâmica da atmosfera dificulta o acerto desses modelos em resoluções espaciais muito finas ou em previsões de curtíssimo prazo (nowcasting) (KUSIAK; ZHENG, 2010). Diante disso, este artigo objetiva analisar como a Inteligência Artificial e o Aprendizado de Máquina despontam como ferramentas transformadoras na modelagem do comportamento do vento, superando as limitações dos métodos clássicos.

2. Marco teórico

2.1. Limitações tradicionais e a ascensão do Machine Learning

Modelos físicos (NWP) baseiam-se na resolução de equações termodinâmicas complexas utilizando supercomputadores. Embora sejam eficientes para projeções de longo prazo (dias), eles são computacionalmente onerosos e frequentemente falham em capturar variações bruscas de vento causadas pela topografia em microescala. Por outro lado, modelos estatísticos puros assumem linearidade nas séries temporais, uma premissa inadequada para a natureza caótica do clima. Segundo Zufferey et al. (2017), o Machine Learning surge para preencher essa lacuna, atuando sob o paradigma de aprendizado orientado a dados (data-driven).

Em vez de programar regras físicas rígidas, algoritmos como Support Vector Machines (SVM) e Árvores de Decisão (Random Forest) são treinados com grandes volumes históricos de dados anemométricos (SCADA) para identificar padrões intrincados e mapear a correlação não linear entre o clima e a velocidade do vento no local da turbina.

2.2. Redes neurais profundas (Deep Learning) em séries temporais

O estado da arte na modelagem computacional atmosférica tem migrado do Machine Learning tradicional para o Deep Learning. A arquitetura das Redes Neurais Artificiais (RNAs) mimetiza o funcionamento cerebral, sendo composta por múltiplas camadas ocultas capazes de abstrair características de alto nível dos dados brutos (GOODFELLOW; BENGIO; COURVILLE, 2016). Na modelagem eólica, destacam-se as Redes Neurais Recorrentes (RNN), especialmente a variante LSTM (Long Short-Term Memory). Diferente das redes tradicionais, as LSTMs possuem "memória", o que lhes permite reter informações sobre ventos passados para prever ventos futuros, tornando-as a arquitetura ideal para o tratamento de séries temporais atmosféricas complexas (WANG et al., 2019).

3. Material e método

Este estudo caracteriza-se como uma pesquisa qualitativa, conduzida através de revisão integrativa da literatura. Para capturar o rápido avanço tecnológico na área, a busca priorizou artigos científicos e proceedings de conferências publicados na última década (2014-2024) nas bases IEEE Xplore, ScienceDirect e Google Acadêmico. Os critérios de seleção englobaram textos que abordassem a transição de métodos estatísticos lineares para técnicas de Inteligência Artificial na área de ciências atmosféricas. A análise dos dados empregou a técnica de categorização, estruturando os achados em ganhos de precisão e limitações computacionais da aplicação da IA no setor.

4. Resultados e discussão

A análise da literatura evidencia que modelos baseados em IA reduzem significativamente métricas de erro como o RMSE (Root Mean Square Error) e o MAE (Mean Absolute Error) em previsões eólicas de curto e curtíssimo prazo (0 a 6 horas). Observa-se que a IA não elimina a necessidade da meteorologia clássica; pelo contrário, a tendência atual são

os "Modelos Híbridos", onde redes neurais são utilizadas para corrigir o viés (bias correction) e refinar os resultados gerados por modelos físicos NWP (KUSIAK; ZHENG, 2010). Apesar dos excelentes resultados preditivos, a literatura levanta gargalos operacionais importantes. O principal desafio reside no caráter de "caixa preta" (black box) das redes neurais profundas, dificultando a interpretabilidade física das previsões pelos meteorologistas (FERREIRA, 2025). Ademais, o treinamento eficaz desses modelos exige infraestrutura de Big Data, demandando que os parques eólicos invistam massivamente na qualidade dos dados observacionais (telemetria e sensores de qualidade) para evitar o fenômeno garbage in, garbage out.

5. Considerações finais

A pesquisa cumpriu seu objetivo ao demonstrar que a Inteligência Artificial é um vetor de inovação indispensável para a modelagem do comportamento do vento. Conclui-se que algoritmos de aprendizado de máquina, em especial as Redes Neurais LSTM, fornecem a agilidade matemática necessária para gerenciar a volatilidade inerente à energia eólica. Como contribuição teórica, este artigo sistematizou a transição tecnológica da previsão eólica para o domínio da ciência de dados. Para pesquisas futuras, sugere-se investigar o conceito de Digital Twins (Gêmeos Digitais) integrados à Inteligência Artificial, avaliando como modelos virtuais sincronizados em tempo real com parques eólicos físicos podem otimizar o diagnóstico de falhas, a predição da esteira aerodinâmica e o controle ativo da potência da usina.

Referências

FERREIRA, Jorge Siqueira de Rezende. A Ousadia de um Empreendedorismo Intrépido com a Evolução da Internet de Fibra e as Mudanças Positivas na Sociedade: The Boldness of Fearless Entrepreneurship with the Evolution of Fiber Internet and Positive Changes in Society. RCMOS - Revista Científica Multidisciplinar O Saber, Brasil, v. 1, n. 1, 2025. DOI: 10.51473/rcmos.v1i1.2025.887.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. Cambridge: MIT Press, 2016.

KUSIAK, Andrew; ZHENG, Haiyang. Optimization of wind turbine energy and power factor with an artificial neural network. Renewable Energy, v. 35, n. 4, p. 736-744, 2010.

SOMAN, S. S. et al. A review of wind power and wind speed forecasting methods with different time horizons. Em: North American Power Symposium 2010, Arlington, 2010, p. 1-8.

WANG, Xin et al. Deep learning-based forecasting in renewable energy. Applied Energy, v. 240, p. 508-522, 2019.