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 inteligencia artificial para modelar el comportamiento del viento: innovaciones en el pronóstico eólico

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

Lucas Emanuel Almeida Barboza

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 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.

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.

1. Introducción

La creciente penetración de la energía eólica en las matrices energéticas globales conlleva un importante desafío operativo: la intermitencia. La imposibilidad de despachar energía eólica bajo demanda exige pronósticos meteorológicos y de generación altamente precisos para que los operadores nacionales del sistema puedan equilibrar la red eléctrica, activando o desactivando otras fuentes de energía en tiempo real (SOMAN et al., 2010). Históricamente, el pronóstico eólico se ha apoyado en modelos de predicción numérica del tiempo (NWP) de mesoescala y métodos estadísticos tradicionales como ARIMA. Sin embargo, la complejidad fluidodinámica de la atmósfera dificulta la precisión de estos modelos en resoluciones espaciales muy finas o en pronósticos de muy corto plazo (nowcasting) (KUSIAK; ZHENG, 2010). Por ello, este artículo analiza cómo la inteligencia artificial y el aprendizaje automático se presentan como herramientas transformadoras para modelar el comportamiento del viento y superar las limitaciones de los métodos clásicos.

2. Marco teórico

2.1. Limitaciones tradicionales y auge del Machine Learning

Los modelos físicos (NWP) se basan en resolver complejas ecuaciones termodinámicas mediante supercomputadoras. Aunque son eficientes para proyecciones de largo plazo, medidas en días, resultan computacionalmente costosos y con frecuencia no captan variaciones bruscas del viento causadas por la topografía a microescala. Los modelos puramente estadísticos, por su parte, suponen linealidad en las series temporales, una premisa inadecuada para la naturaleza caótica del clima. Según Zufferey et al. (2017), el Machine Learning surge para cubrir esta brecha mediante el paradigma de aprendizaje orientado a datos (data-driven). En lugar de

programar reglas físicas rígidas, algoritmos como las máquinas de vectores de soporte (SVM) y los árboles de decisión (Random Forest) se entrenan con grandes volúmenes históricos de datos anemométricos (SCADA) para identificar patrones intrincados y mapear la correlación no lineal entre el clima y la velocidad del viento en la turbina.

2.2. Redes neuronales profundas (Deep Learning) en series temporales

El estado del arte del modelado atmosférico computacional ha migrado del Machine Learning tradicional hacia el Deep Learning. La arquitectura de las redes neuronales artificiales (RNA) imita el funcionamiento cerebral y está compuesta por múltiples capas ocultas capaces de abstraer características de alto nivel de los datos brutos (GOODFELLOW; BENGIO; COURVILLE, 2016). En el modelado eólico destacan las redes neuronales recurrentes (RNN), especialmente la variante LSTM (Long Short-Term Memory). A diferencia de las redes tradicionales, las LSTM poseen "memoria", lo que les permite retener información sobre vientos pasados para pronosticar vientos futuros y las convierte en una arquitectura ideal para tratar series temporales atmosféricas complejas (WANG et al., 2019).

3. Materiales y método

Este estudio se caracteriza como una investigación cualitativa realizada mediante revisión integradora de la literatura. Para captar el rápido avance tecnológico del área, la búsqueda priorizó artículos científicos y actas de congresos publicados durante la última década (2014-2024) en IEEE Xplore, ScienceDirect y Google Académico. Los criterios de selección abarcaron textos sobre la transición desde métodos estadísticos lineales hacia técnicas de inteligencia artificial en las ciencias atmosféricas. El análisis de los datos utilizó una técnica de categorización que organizó los hallazgos según las mejoras de precisión y las limitaciones computacionales de la aplicación de IA en el sector.

4. Resultados y discusión

El análisis de la literatura evidencia que los modelos basados en IA reducen significativamente métricas de error como RMSE (raíz del error cuadrático medio) y MAE (error absoluto medio) en pronósticos eólicos de corto y muy corto plazo (0 a 6 horas). La IA no elimina la necesidad de la meteorología clásica; por el contrario, la tendencia actual son los

"modelos híbridos", en los que las redes neuronales corrigen el sesgo y refinan los resultados generados por modelos físicos NWP (KUSIAK; ZHENG, 2010). Pese a los excelentes resultados predictivos, la literatura señala importantes cuellos de botella operativos. El principal desafío reside en el carácter de "caja negra" de las redes neuronales profundas, que dificulta la interpretación física de los pronósticos por parte de los meteorólogos. Además, entrenar eficazmente estos modelos exige infraestructura de Big Data y obliga a los parques eólicos a invertir intensamente en la calidad de los datos observacionales, incluidos telemetría y sensores de calidad, para evitar el fenómeno garbage in, garbage out.

5. Consideraciones finales

La investigación cumplió su objetivo al demostrar que la inteligencia artificial es un vector de innovación indispensable para modelar el comportamiento del viento. Se concluye que los algoritmos de aprendizaje automático, especialmente las redes neuronales LSTM, proporcionan la agilidad matemática necesaria para gestionar la volatilidad inherente a la energía eólica. Como contribución teórica, este artículo sistematizó la transición tecnológica del pronóstico eólico hacia el dominio de la ciencia de datos. Para futuras investigaciones se sugiere estudiar los gemelos digitales integrados con inteligencia artificial y evaluar cómo los modelos virtuales sincronizados en tiempo real con parques eólicos físicos pueden optimizar el diagnóstico de fallas, la predicción de la estela aerodinámica y el control activo de la potencia de la planta.

Referencias

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.

ZUFFEREY, T. et al. Machine learning-based wind power forecasting. Energy Procedia, v. 122, p. 797-802, 2017.