



03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Análise de métodos de previsão de geração de energia eólica: uma revisão sistemática da literatura

Andreia Aparecida da Silva

Programa de Pós-Graduação em Engenharia de Produção e Sistemas – Universidade Tecnológica Federal do Paraná, UTFPR

Fernando José Avancini Schenatto

Programa de Pós-Graduação em Engenharia de Produção e Sistemas – Universidade Tecnológica Federal do Paraná, UTFPR

Matheus Henrique Dal Molin Ribeiro

Programa de Pós-Graduação em Engenharia de Produção e Sistemas – Universidade Tecnológica Federal do Paraná, UTFPR

Resumo: A previsão da geração de energia eólica é essencial para o controle e o planejamento dos sistemas elétricos. O aumento da participação dessa fonte na matriz energética mundial tem incentivado o desenvolvimento de métodos de previsão capazes de lidar com a variabilidade e a incerteza associadas à velocidade do vento. Nesse contexto, o objetivo desse artigo é identificar, classificar e analisar os métodos empregados para previsão da geração de energia eólica. Para tanto, fez-se o uso do método ProKnow-C (*Knowledge Development Process – Constructivist*), delimitando-se a busca a partir das bases *Scopus*, *Web of Science* e *IEEE Xplore*, com recorte temporal para artigos publicados entre 2015 e 2025. Um total de 24 artigos compõem o portfólio final relacionado com o tema. A partir disso, procedeu-se a análise bibliométrica e de conteúdo, com o intuito de identificar os autores e periódicos mais destacados, bem como, os métodos de previsão utilizados nos artigos. Os resultados mostraram que os periódicos *Energy Conversion and Management*, *Renewable Energy* e o *IEEE Transactions on Sustainable Energy* foram os principais do portfólio final, com participação de 12,5% para o primeiro e 8,3% de participação para o segundo e terceiro. As três classificações de abordagens de previsão mais utilizados nos artigos que compõem o portfólio foram: ML- NN (29,9%), ML- Híbrido (25,7%), ML- Ensemble (25,1%). Essa revisão sistemática de literatura contribui para o avanço do conhecimento na área de previsão de energia eólica, ao oferecer um panorama consolidado dos principais métodos atualmente empregados pela comunidade científica.

Palavras-chave: energia eólica, velocidade do vento, previsão de séries temporais, CONBREPRO, CIGELUBRA.

Analysis of Wind Power Generation Forecasting Methods: A Systematic Literature Review

Abstract: Wind power generation forecasting is essential for the control and planning of electrical systems. The increase in the share of this source in the global energy matrix has encouraged the development of forecasting methods capable of dealing with the variability and uncertainty associated with wind speed. In this context, the objective of this article is to identify, classify, and analyze the methods used to forecast wind power generation. To this end, the ProKnow-C (*Knowledge Development Process – Constructivist*) method was used, limiting the search to the

Scopus, Web of Science, and IEEE Xplore databases, with a time frame for articles published between 2015 and 2025. A total of 24 articles made up the final portfolio related to the topic. From this, a bibliometric and content analysis was performed to identify the most prominent authors and journals, as well as the forecasting methods used in the articles. The results showed that the journals Energy Conversion and Management and Renewable Energy were the main ones in the final portfolio, with a share of 15.7% and 10.5%, respectively. The three most commonly used forecasting approaches in the articles that make up the portfolio were: ML-NN (29.9%), ML-Hybrid (25.7%), and ML-Ensemble (25.1%). This systematic review of the literature contributes to the advancement of knowledge in the field of wind energy forecasting by providing a consolidated overview of the main methods currently employed by the scientific community.

Keywords: wind energy, wind speed, time series forecasting, CONBREPRO, CIGELUBRA.

1. Introdução

As fontes de energia renovável têm ampliado sua participação na matriz energética mundial, aproveitando recursos abundantes e inesgotáveis como vento, sol, rios e biomassa, que permitem gerar energia limpa sem emissões de gases de efeito estufa. Esse cenário tem incentivado muitos países a aderirem à transição energética, substituindo gradualmente fontes fósseis por renováveis, tema debatido na Conferência das Nações Unidas sobre Mudanças Climáticas (COP28), com metas de expansão da capacidade instalada de energia limpa até 2030 (IEA, 2024)

Segundo o *World Wind Energy Association* (WWEA) em 2024, a capacidade de energia eólica instalada no mundo atende 10% de toda a demanda global de eletricidade. No contexto regional, nesse mesmo ano, na América do Sul o Brasil é considerado o país que mais produz energia eólica, o qual teve um aumento anual de 19% na capacidade instalada, situando-se entre os dez principais mercados eólicos. Referindo-se ao consumo de energia elétrica, o Brasil atingiu a marca de 77 mil *megawatts* (MW) médio consumidos em um único mês, representando um aumento de 4,9% no mês de fevereiro de 2025 em relação ao mesmo mês em 2024 (WWEA, 2025).

Na comunidade científica, diversos estudos estão relacionados à previsão de geração de fontes de energia renovável. Os autores Srinivasagan *et al.* (2024) realizaram a previsão de capacidade de painéis solares na Arábia Saudita, já Stefenon *et al.* (2023) realizaram a previsão para o nível de barragens em usinas hidrelétricas, Alves Ribeiro *et al.* (2020) geraram a previsão de vazões em cinco usinas hidrelétricas, e os autores Harrou *et al.* (2019), Zhao *et al.* (2024) e Nayak *et al.* (2025) realizaram previsões para energia eólica. No entanto, as previsões de geração de energia eólica vêm se destacando devido à sua dependência da velocidade do vento para geração de energia, objeto desse estudo.

Muitos pesquisadores tem se dedicado a essa área, visto que realizar a modelagem de dados de velocidade do vento é uma tarefa desafiadora em razão a flutuação descontínua, influenciada por condições climáticas. Além disso, realizar previsões da geração de energia é fundamental para tomada de decisão pois permite um planejamento energético, operações de sistemas elétricos e também a inserção de outras fontes de energia para atender a demanda elétrica e para uma previsão precisa é necessário a utilização de técnicas de modelagem avançadas que sejam capazes de capturar a complexidade e não linearidade dos dados. Diante do exposto, o presente artigo consiste em uma revisão sistemática de literatura, com o objetivo de identificar, classificar e analisar os métodos empregados para previsão da geração de energia eólica.

As principais contribuições desse estudo são:

- Aplicação do método ProKnow-C (*Knowledge Development Process – Constructivist*) para a construção de um portfólio bibliográfico no contexto de previsão de séries temporais relacionados a geração de energia eólica;

- Realização de uma análise bibliométrica destacando principais periódicos e pesquisadores de destaque no contexto de previsão de energia eólica;
- Identificar e apresentar os métodos de previsão mais recorrentes no portfólio bibliográfico final, baseado em cinco classificações metodológicas.

Esse trabalho apresenta na sequência o referencial teórico, a metodologia adotada para a pesquisa, prosseguindo com a apresentação dos resultados consolidados, ao que segue a discussão e conclusões.

2. Referencial teórico

Nesse capítulo serão apresentados os conceitos relacionados a conceitualização de análise de séries temporais, métodos de previsão e técnicas de ensemble.

2.1 Análise e previsão de séries temporais de geração de energia eólica

Uma série temporal é um conjunto de dados coletados ao longo do tempo, cuja análise possibilita identificar padrões, como tendência, sazonalidade e ciclos, além de realizar previsões úteis ao planejamento estratégico (SOUSA *et al.*, 2021). A energia eólica, obtida pela conversão da energia cinética do vento em eletricidade, destaca-se por ser limpa, de baixo custo e reduzir a dependência de fontes mais caras (BRAZ *et al.*, 2017). Assim, a análise de séries temporais da geração eólica torna-se fundamental para compreender suas particularidades, apoiar a modelagem, melhorar as previsões e contribuir para o planejamento energético, reduzindo os efeitos da variabilidade do vento sobre os sistemas elétricos.

2.2 Modelos de previsão

A escolha do modelo de previsão depende da disponibilidade de dados: métodos qualitativos são usados na ausência de informações históricas, enquanto métodos quantitativos se aplicam quando há registros passados, podendo ser de séries temporais ou explicativos, estes últimos incorporando variáveis adicionais (HYNDMAN; ATHANASOPOULOS, 2021). Nesse contexto, os modelos estatísticos de séries temporais buscam descrever matematicamente os padrões presentes nos dados para gerar previsões mais próximas da realidade. Tais modelos podem assumir diferentes formas, como regressão, autorregressão ou modelos estruturais, sendo estes últimos capazes de incorporar a aleatoriedade diretamente na estrutura sistemática da série por meio da adição de ruídos brancos (SOUSA *et al.*, 2021).

Além dos modelos estatísticos, destacam-se as técnicas de aprendizado de máquina (do inglês, *Machine Learning*, ML), área da inteligência artificial em que os modelos aprendem a partir dos dados. O ML pode ser dividido em aprendizagem supervisionada, voltada à construção de modelos preditivos baseados na relação entre variável-alvo e preditoras, e aprendizagem não supervisionada, que busca padrões e agrupamentos sem depender de uma variável-alvo (BOEHMKE; GREENWELL, 2019). Uma técnica de técnicas de aprendizado de máquina amplamente utilizada são as Redes Neurais Artificiais (do inglês, *Artificial Neural Networks*, ANN) inspirados no funcionamento do cérebro, baseados em modelos matemáticos que permitem capturar relações complexas e não lineares entre a variável de interesse e seus preditores (HYNDMAN; ATHANASOPOULOS, 2021). Além disso, essas redes, nesse estudo denotada por ML-NN, frequentemente servem como base para o desenvolvimento de outros modelos mais avançados, como rede neural convolucional (do inglês, *Convolutional Neural Network*, CNN), máquina de aprendizado extremo (do inglês, *Extreme Learning Machine*, ELM) e perceptron multicamadas (do inglês, *Multilayer Perceptron*, MLP).

Os modelos ensemble dividem-se em ML-Híbridos (colaborativos) e ML-Ensemble (competitivos). As abordagens de previsão ML-Ensemble utilizam múltiplos preditores com

variações para gerar previsões individuais que são combinados para formar um modelo de previsão por conjunto. Os modelos de previsão por conjunto agregam os resultados individuais, geralmente pela média, e utilizam a dispersão desses resultados para medir confiança. A diversidade entre os preditores é essencial: quanto mais diferentes forem suas saídas, maior a eficácia do modelo de conjunto (REN *et al.*, 2015). Por exemplo: florestas aleatórias (do inglês, *Random Forest*, RF), XGBoost (*eXtreme Gradient Boosting*) e *Bagging*.

Abordagens ML-Híbridos integram diferentes preditores em um mesmo sistema, buscando elevar a precisão das previsões e reduzir os erros. Nessa perspectiva, os métodos híbridos organizam o processo preditivo em múltiplas subtarefas, de modo que o preditor mais apropriado seja aplicado conforme as características específicas de cada uma delas. A predição final pode ser obtida pela combinação de preditores base, técnicas de pré-processamento, metaheurísticas e modelos estatísticos ou de inteligência artificial (GUINDANI *et al.*, 2024).

3. Metodologia


Nessa seção serão descritos os processos utilizados para seleção e análise dos artigos que formaram o portfólio bibliográfico desse estudo.

3.1 Seleção de artigos dos Portfólio Bibliográfico

Para o desenvolvimento da RSL o método utilizado foi o Proknow-C, que consiste em uma metodologia estruturada de construção de conhecimento científico, com o intuito de selecionar, analisar e organizar um portfólio representativo sobre um tema específico, no caso desse estudo previsão de energia eólica (ENSSLIN *et al.*, 2013)

Esse método é composto por várias etapas, e são apresentadas de maneira resumida na Figura 1.

Figura 1 - Processos para seleção do portfólio utilizando o Proknow-C



Fonte: Adaptado de Ensslin *et al.* (2013)

Essa metodologia é composta por vários procedimentos sequenciais, até obtenção do portfólio final. Afonso *et al.* (2012) menciona que primeiramente, deve-se definir os eixos da pesquisa, e em cada eixo atribuir palavras-chave que serão utilizadas como mecanismo de busca, a saber, o primeiro eixo definido foi métodos de *ensemble* e as palavras-chave

atribuídas *bagging* e *bootstrap*, e o segundo eixo, fontes de energia renováveis, o qual ainda foi subdividido em (a) energia eólica e (b) energias renováveis, as palavras-chave escolhidas para (a) foram, *wind energy*, *wind speed*, e para (b) *photovoltaic* e *hydraulic*. Vale ressaltar que a princípio um eixo de modelos de previsão havia sido definido, porém as palavras-chave definidas restringem demais a busca, por isso optou-se pelo uso de apenas dois eixos.,

Em seguida, testou-se várias combinações dessas palavras chaves usando o operador AND e OR, e assim dez combinações foram obtidas. As combinações foram "bootstrap" AND "renewable energy"; "bagging" AND "renewable energy"; "bootstrap" AND "wind energy"; "bagging" AND "wind energy"; "bootstrap" AND "wind speed"; "bootstrap" AND ("hydroelectric" OR "photovoltaic" AND "energy") e por fim "bagging" AND ("hydroelectric" OR "photovoltaic" AND "energy"). As bases *Scopus*, *Web of Science* e *IEEE Xplore* foram escolhidas por sua ampla cobertura de publicações científicas com rigor acadêmico em engenharia, energia renovável e tecnologia aplicada, incluindo os principais periódicos dessas áreas. Ao aplicar as combinações de palavras-chave, verificou-se que elas representavam satisfatoriamente o tema da pesquisa. O teste de aderência confirmou essas escolhas, sem necessidade de acrescentar novas palavras-chave ou bases. Com a importação dos artigos dessas bases, o banco bruto ficou composto por 1.140 artigos, gerenciados pelo *Mendeley*, abrangendo publicações de 2015 a 2025.

A primeira etapa da filtragem do banco de artigos consistiu na remoção de duplicatas, resultando em 719 artigos para a próxima análise. Na segunda etapa, a leitura dos títulos revelou que apenas 164 artigos estavam alinhados com o tema da pesquisa. Na terceira etapa, foi avaliada a relevância científica desses 164 artigos, dividindo-os em dois grupos: Grupo 1, com dez ou mais citações, e Grupo 2, com menos de dez citações. A leitura dos resumos indicou que 129 artigos não atendiam à proposta da pesquisa. Posteriormente, foram lidos na íntegra 35 artigos, dos quais apenas 24 artigos compuseram o portfólio final, apresentado na Tabela 1, em ordem cronológica de publicação.

Tabela 1 - Portfólio bibliográfico

Ano	Autores	Título do artigo	Número de citações
2015	Errouissi <i>et al.</i>	<i>Bootstrap Prediction Interval Estimation for Wind Speed Forecasting</i>	40
2015	Alvarez-Miranda <i>et al.</i>	<i>Two-stage robust UC including a novel scenario-based uncertainty model for wind power applications</i>	23
2016	Paramasivan e Lopez	<i>Forecasting of Wind Speed Using Feature Selection and Neural Networks</i>	46
2017	Peng <i>et al.</i>	<i>Multi-step ahead wind speed forecasting using a hybrid model based on two-stage decomposition technique and AdaBoost-extreme learning machine</i>	163
2018	Mahmoud <i>et al.</i>	<i>An advanced approach for optimal wind power generation prediction intervals by using self-adaptive evolutionary extreme learning machine</i>	106
2019	Ma <i>et al.</i>	<i>Particle-swarm optimization of ensemble neural networks with negative correlation learning for forecasting short-term wind speed of wind farms in western China</i>	59
2020	Abedinia <i>et al.</i>	<i>Improved EMD-Based Complex Prediction Model for Wind Power Forecasting</i>	218
2020	Quan e Shang	<i>Short-Term Wind Speed Forecasting Based on Ensemble Online Sequential Extreme Learning Machine and Bayesian Optimization</i>	11
2020	Zhang <i>et al.</i>	<i>Wind speed interval prediction based on lorenz disturbance distribution</i>	62

2021	Li et al.	<i>A wind speed interval forecasting system based on constrained lower upper bound estimation and parallel feature selection</i>	34
2021	Al-Dahidi et al.	<i>Bootstrapped ensemble of artificial neural networks technique for quantifying uncertainty in prediction of wind energy production</i>	12
2022	Chen	<i>Cluster-based ensemble learning for wind power modeling from meteorological wind data</i>	24
2022	Ribeiro et al.	<i>Efficient bootstrap stacking ensemble learning model applied to wind power generation forecasting</i>	150
2022	Dhibi et al.	<i>Reduced neural network based ensemble approach for fault detection and diagnosis of wind energy converter systems</i>	40
2022	Tarek et al.	<i>Wind Power Prediction Based on Machine Learning and Deep Learning Models</i>	57
2023	Qu et al.	<i>A D-stacking dual-fusion, spatio-temporal graph deep neural network based on a multi-integrated overlay for short-term wind-farm cluster power multi-step prediction</i>	19
2023	Alkabbani et al.	<i>Machine Learning-based Time Series Modelling for Large-Scale Regional Wind Power Forecasting: a Case Study in Ontario, Canada</i>	20
2023	Liao et al.	<i>Ultra-short-term Interval Prediction of Wind Power Based on Graph Neural Network and Improved Bootstrap Technique</i>	51
2024	Elmousalami et al.	<i>A comprehensive evaluation of machine learning and deep learning algorithms for wind speed and power prediction</i>	8
2024	Carrera e Kim	<i>Comparative Analysis of Machine Learning Techniques in Predicting Wind Power Generation: A Case Study of 2018-2021 Data from Guatemala</i>	4
2024	Biswas et al.	<i>Performance Analysis of Short and Mid-Term Wind Power Prediction using ARIMA and Hybrid Models</i>	53
2025	Nguinabé et al.	<i>Bootstrap prediction intervals for the long short term memory (LSTM) recurrent neural network</i>	1
2025	Rathnayake et al.	<i>Predicting Short-Term Wind Power Generation at Musalpetti Wind Farm: Model Development and Analysis</i>	0
2025	Nayak et al.	<i>Probabilistic online learning framework for short-term wind power forecasting using ensemble bagging regression model</i>	6

Fonte: Elaborado pelos autores (2025)

Após a definição do portfólio final, foi realizada uma identificação detalhada dos métodos de previsão adotados nos artigos. Assim, os métodos foram categorizados em: (i) métodos estatísticos; (ii) métodos de Machine Learning (ML) (Alfred et al. 2022); (iii) métodos Machine Learning – Artificial Neural Network (ML – ANN) (SALDAÑA et al., 2020) (iv) métodos ML – Ensemble; e (v) métodos ML – Híbrido (RIBEIRO, 2021).

4. Resultados

Nessa seção serão expostos os resultados obtidos na análise bibliométrica, como também, apresentado a análise do conteúdo que compõe o portfólio bibliográfico.

4.1 Análise bibliométrica do portfólio bibliográfico obtido

Como etapa complementar à construção do portfólio bibliográfico, a análise bibliométrica dos artigos obtidos é realizada. O intuito dessa análise consiste em destacar as informações

relevantes sobre o portfólio bibliográfico, por meio da análise e quantificação de suas características (AFONSO *et al.*, 2012).

Em uma análise do número de artigos que compõem o portfólio bibliográfico observou-se que a maioria dos artigos estão diluídos em periódicos diferentes, mas o *Energy Conversion and Management* se destaca em relação aos demais por concentrar 3 artigos desse portfólio, enquanto o *Renewable Energy* e o *IEEE Transactions on Sustainable Energy* concentra 2 artigos. Já em relação aos 19 demais trabalhos, estes estão publicados em distintos periódicos.

Referindo-se ao nível de impacto dos periódicos nesse portfólio tem-se o *Renewable and Sustainable Energy Reviews* com maior reconhecimento acadêmico e um expressivo impacto internacional, com cite score 38. Em segundo lugar do periódico *Energy Conversion and Management* e terceiro lugar, *Renewable and Sustainable*, com cite score de 19,8 e 17,6, respectivamente. Dessa forma, fica evidente que os artigos selecionados foram publicados em periódicos de elevada relevância científica, conferindo maior credibilidade às metodologias e resultados apresentados.

A análise dos autores presente nesse portfólio mostra uma distribuição bastante diversificada, com apenas um autor, a saber, Jianzhou Wang, sendo citado em dois trabalhos distintos. Ainda nesse contexto, os trabalhos mais citados que compõem o portfólio bibliográfico estão apresentados na Tabela 2, em ordem decrescente por número de citações.

Tabela 2 - Artigos do portfólio bibliográfico com mais citações.

Ano	Autores	Número de citações	Bases
2020	Abedinia, <i>et al.</i>	218	IEEE Xplore
2017	Peng <i>et al.</i>	163	Scopus
2022	Ribeiro <i>et al.</i>	150	Scopus
2018	Mahmoud <i>et al.</i>	106	Scopus
2020	Zhang <i>et al.</i>	62	IEEE Xplore
2019	Ma <i>et al.</i>	59	Scopus
2022	Tarek <i>et al.</i>	57	Web of Science
2024	Biswas <i>et al.</i>	53	IEEE Xplore
2023	Liao <i>et al.</i>	51	IEEE Xplore
2016	Paramasivan e Lopez	46	Web of Science


Fonte: Elaborado pelos autores (2025)

A participação das bases no portfólio bibliográfico corresponde a: i) Scopus (55%); ii) IEEE Xplore (35,3%) e iii) Web of Science (9,7%). As citações apresentadas na Tabela 2, correspondem a 80% do total de citações que compõem os artigos do portfólio, além disso, nota-se que os artigos com mais 100 citações estão nas bases Scopus e IEEE Xplore.

4.2 Análise de conteúdo

Os métodos identificados nos 24 artigos do portfólio final foram classificados em: estatísticos; ML; ML – ANN; ML – Ensemble; e ML – Híbrido. A Figura 5 ilustra a participação de cada uma das categorias na composição do portfólio.

Figura 2 - Distribuição das categorias metodológicas dos modelos aplicados no portfólio bibliográfico.



Fonte: Elaborado pelos autores (2025)

Conforme ilustrado na Figura 3, as categorias ML-NN, ML-Híbrido e ML-Ensemble apresentam participação predominante no portfólio, correspondendo a mais de 80% do total. A categoria ML corresponde a 12%, refletindo a transição metodológica desta categoria para ML-Híbrido, que é uma abordagem mais avançada e, nesse portfólio, apresenta uma participação de 25,7%. Observa-se também que, apesar das limitações típicas na modelagem e previsão da velocidade do vento, os modelos estatísticos ainda são bastante utilizados, representando 7,19% do portfólio.

Com base na análise das citações, foram selecionados os dez trabalhos mais relevantes do portfólio bibliográfico, listados na Tabela 2, cujas principais abordagens metodológicas serão detalhadas a seguir. Observa-se que diferentes autores têm proposto métodos ML-Híbridos baseados na integração de algoritmos de ML-NN com técnicas de decomposição avançadas e variadas. Como nos estudos de Abedinia *et al.* (2020), que propuseram uma nova versão da decomposição de modo empírico (do inglês, *Improved version of Empirical Mode Decomposition*, IEMD), para decompor as medições do vento, após decomposição sinal, os componentes obtidos são usados como entrada em um modelo híbrido de previsão, que combina rede neural com bagging (do inglês, *Bagging Neural Network*, BaNN) e K-means clustering e um algoritmo de otimização estocástica. Os autores consideraram três estudos de caso, sendo o primeiro em um Parque Eólico de Sotavento, Parques Eólicos de Alberta e o Parque Eólico D. Blue Canyon. De maneira semelhante, Peng *et al.* (2017) desenvolveram um modelo híbrido para previsão de curto prazo da velocidade do vento, no interior da Mongólia, China, combinando o algoritmo AdaBoost.RT com ELM e um processo de decomposição em dois estágios que integra decomposição complementar de modos empíricos de conjunto com ruído adaptativo (do inglês, *Complementary Ensemble Empirical Mode Decomposition With Adaptive Noise*, CEEMDAN) e a decomposição de modo variacional (do inglês, *Variational Mode Decomposition*, VMD) para lidar com a não linearidade da série temporal.

Alguns estudos também têm explorado métodos *ensemble*, como nos estudos de Ribeiro *et al.* (2022), que combinaram um modelo de aprendizado por conjunto com uma abordagem de bagging e stacking para prever a geração de energia eólica de dois parques eólicos localizados no estado da Bahia, Brasil. Já Mahmoud *et al.* (2018) propuseram em seu artigo, um novo algoritmo que é composto pelo modelo ELM e máquina de aprendizado extremo evolucionárias auto- adaptativas (do inglês, *Self-Adaptive Evolutionary Extreme Learning Machines*, SAEELM) para modelar intervalos de previsão de geração de energia eólica de 19 parques eólicos de New South Wales e South Australia, ambos na Austrália. No estudo de Zhang *et al.* (2020), os autores propuseram um método híbrido que combina

uma rede neural RBF com a decomposição em modo empírico (do inglês, *Empirical Mode Decomposition*, EMD) e a sequência de perturbação de Lorenz (do inglês, *Lorenz Disturbance Sequence*, LDS). Para estimar a distribuição de densidade de probabilidade da LDS, são utilizados os métodos *Bootstrap* e estimativa de densidade via Kernel. Além disso, aplica-se também a regressão quantílica para realizar a previsão intervalar da velocidade do vento do Parque eólico de Sotavento, localizado na Espanha.

Além dos estudos mencionados, alguns autores também têm incorporado métodos de otimização em suas abordagens híbridas, como por exemplo Ma *et al.* (2019) que apresentou uma abordagem chamada WAT-NCL-PSO que utiliza a técnica de análise *wavelet* (do inglês, *Wavelet Analysis Technique*, WAT) para redução de ruído, um conjunto de redes neurais de aprendizagem de correlação negativa (do inglês, *Negative Correlation Learning Neural Network*, NCL-NN) e uma estrutura de conjunto otimizada usando otimização de enxame de partículas (do inglês, *Particle-Swarm Optimization*, PSO), com o objetivo de prever a velocidade do vento de curto prazo. Essa abordagem foi aplicada em dados de velocidade do vento de seis parques eólicos, localizados no oeste da China. Os autores Tarek *et al.* (2022) propuseram uma nova técnica de otimização baseada em busca fractal estocástica e otimização por enxame de partículas (do inglês, *Stochastic Fractal Search and Particle Swarm Optimization*, SFS-PSO) para otimizar os parâmetros da rede LSTM e prever a geração de energia eólica.

Já nos estudos de Biswas *et al.* (2021), uma combinação de métodos de regressão e aprendizado de máquina, como ARIMA, RF, árvores de classificação e regressão bagging (do inglês, *Bagging Classification and Regression Trees*, BCART) e dois modelos híbridos de ARIMA-RF e ARIMA-BCART são propostos para prever a geração de energia eólica de parques eólicos da costa leste e oeste dos Estados Unidos. Os autores Liao *et al.* (2023), propuseram um novo método para previsão de intervalo de ultracurto prazo da energia eólica com base em uma rede neural de grafos (do inglês, *Graph Neural Network*, GNN) e uma técnica *Bootstrap* aprimorada. Já na pesquisa de Paramasivan e Lopez (2016), o objetivo consiste em prever a velocidade do vento usando o método de seleção de características ReliefF e uma rede neural *bagging* (do inglês, *Bagging Neural Network*, BNN).

Os estudos apresentados mostram a predominância de abordagens ML-Híbridas que combinam diferentes métodos ML- Ensembles, ML- NN, ML e estatísticos, como também a integração de métodos de decomposição e técnicas de otimização, a fim de melhorar a precisão e minimizar a incerteza na produção eólica. Assim, a revisão sistemática destacou a importância da previsão para apoiar operadores de sistemas elétricos frente à variabilidade da geração, demanda e condições meteorológicas, ressaltando ainda que a escolha de metodologias apropriadas contribui para a eficiência operacional e a integração da energia eólica.

5. Conclusões

O objetivo da presente pesquisa foi realizar um levantamento bibliográfico relacionado as metodologias de previsão de séries temporais para a geração de energia eólica. Para que o objetivo fosse alcançado utilizou-se a metodologia ProKnow-C, resultando na seleção de 24 artigos pertinentes ao tema. Dessa forma, as abordagens utilizadas nos artigos que compõem o portfólio foram relacionadas e analisadas por classificação, (i) ML; (ii) ML – ANN; (iii) ML – Ensemble; (iv) ML-híbrido; e (v) Estatístico. Dessa forma, foi verificado que os modelos classificados em ML- NN foram mais utilizados, correspondendo a 29,9%, enquanto os modelos classificados como ML- Híbrido e ML- Ensemble correspondem a 24,7% e 25,1%, respectivamente.

Em relação aos periódicos, o *Energy Conversion and Management* foi o que teve maior participação no portfólio final, contendo 3 artigos do portfólio e correspondendo a 12,5%.

Em destaque também pode-se mencionar o periódico *Renewable Energy* e o *IEEE Transactions on Sustainable Energy* que tiveram participação de 8,3% no portfólio final. Além disso, o autor que se destacou com maior recorrência no portfólio foi Jianzhou Wang.

Embora os métodos híbridos de aprendizado de máquina estejam ganhando destaque, ainda há lacunas quanto a comparações com modelos tradicionais, além da necessidade de maior investigação sobre sua robustez, interpretabilidade e aplicabilidade em diferentes horizontes de previsão e conjuntos de dados. Nesse sentido, a identificação das abordagens realizada neste trabalho mostra-se relevante, pois permite selecionar técnicas adequadas que contribuam para a tomada de decisão na geração de energia eólica, otimizando a produção e a eficiência operacional. Como proposta para pesquisas futuras sugere-se que a abordagem adotada nesse estudo seja aplicada em outros contextos, como na previsão de energia fotovoltaica ou hidrelétrica, bem como, abranger estudos focados em metodologias por *ensembles* ou apenas híbridas, as quais tem se mostrado promissoras na literatura.

Referências

ABEDINIA, O.; *et al.* Improved EMD-Based Complex Prediction Model for Wind Power Forecasting. **IEEE Transactions On Sustainable Energy**, v. 11, n. 4, p. 2790–2802, out 2020.

AFONSO, M. H. F.; *et al.* Como construir conhecimento sobre o tema de pesquisa? Aplicação do processo Proknow-c na busca de literatura sobre avaliação do desenvolvimento sustentável. **Revista de Gestão Social e Ambiental**, v. 5, n. 2, 27, fev 2012.

AL-DAHIDI, S.; *et al.* Bootstrapped ensemble of artificial neural networks technique for quantifying uncertainty in prediction of wind energy production. **Sustainability (Switzerland)**, v. 13, n. 11, 2021.

ALFRED, R.; *et al.* Modelling and Forecasting Fresh Agro-Food Commodity Consumption Per Capita in Malaysia Using Machine Learning. **Wiley Online Library**, v. 2022, p. 17, 2022.

ALKABBANI, H.; *et al.* Machine Learning-based Time Series Modelling for Large-Scale Regional Wind Power Forecasting: a Case Study in Ontario, Canada. **Cleaner Energy Systems**, v. 5, 2023.

ALVAREZ-MIRANDA, Eduardo e CAMPOS-VALDES, Camilo e RAHMANN, Claudia. Two-stage robust UC including a novel scenario-based uncertainty model for wind power applications. **Energy Conversion And Management**, v. 101, p. 94–105, set 2015.

RIBEIRO, V H. A.; REYNOSO-MEZA, G.; SIQUEIRA, H. V. Multi-objective ensembles of echo state networks and extreme learning machines for streamflow series forecasting. **Engineering Applications Of Artificial Intelligence**, v. 95, out 2020.

BISWAS, A. K.; *et al.* Performance Analysis of Short and Mid-Term Wind Power Prediction using ARIMA and Hybrid Models. **IEEE Power and Energy Conference at Illinois**, 2021.

BOEHMKE, B.; GREENWELL, B. **Hands-On Machine Learning with R**. 1. ed. New York: Chapman and Hall/CRC, 2019. Acesso em: 21 jul 2025.

BRAZ, C. A.; RODRIGUES, R. L.; SIQUEIRA, H. V. Geração de energia elétrica por meio de fontes de energias renováveis: uma revisão sistemática da literatura sobre energia eólica. **Revista Gestão Industrial**, v. 13, n. 1, p. 228, set 2017.

CARRERA, B.; KIM, K. Comparative Analysis of Machine Learning Techniques in Predicting Wind Power Generation: A Case Study of 2018-2021 Data from Guatemala. **Energies**, v. 17, n. 13, jul 2024.

CCEE. **Consumo de energia no Brasil cresce 4,9% em fevereiro e supera os 77 mil MW médios pela primeira vez, calcula CCEE - CCEE**. Disponível em: <<https://www.ccee.org.br/pt/web/guest/-/consumo-de-energia-no-brasil-cresce-4-9-em-fevereiro-e-supera-os-77-mil-mw-medios-pela-primeira-vez-calcula-ccee>>. Acesso em: 20 jul 2025.

CHEN, H. Cluster-based ensemble learning for wind power modeling from meteorological wind data. **Renewable & Sustainable Energy Reviews**, v. 167, out 2022.

CORDEIRO, A. M.; *et al.* Revisão sistemática: uma revisão narrativa. **Revista do Colégio Brasileiro de Cirurgiões**, v. 34, n. 6, p. 428–431, 2007.

DHIBI, Khaled.; *et al.* Reduced neural network based ensemble approach for fault detection and diagnosis of wind energy converter systems. **Renewable Energy**, v. 194, p. 778–787, jul 2022.

ELMOUSALAMI, H.; *et al.* A comprehensive evaluation of machine learning and deep learning algorithms for wind speed and power prediction. **Decision Analytics Journal**, v. 13, 2024.

ENSSLIN, L.; ENSSLIN, S. R.; PINTO, H. M. Processo de investigação e análise bibliométrica: avaliação da qualidade dos serviços bancários. **Revista de Administração Contemporânea**, v. 17, n. 3, p. 325–349, jun 2013.

ERROUISSI, R.; *et al.* Bootstrap Prediction Interval Estimation for Wind Speed Forecasting. **IEEE Energy Conversion Congress and Exposition**, p. 1919–1924, 2015.

GUINDANI, L. G.; *et al.* Exploring current trends in agricultural commodities forecasting methods through text mining: Developments in statistical and artificial intelligence methods. **Helyon**, v. 10, n. 23, dez 2024.

HARROU, F.; SAIDI, A.; SUN, Y. Wind power prediction using bootstrap aggregating trees approach to enabling sustainable wind power integration in a smart grid. **Energy Conversion and Management**, v. 201, p. 112077, 1 dez 2019.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 3. ed. Melbourne: OTexts, 2021. Acesso em: 21 jul 2025.

IEA. **Renewable 2024. Global overview**. Disponível em: <<https://www.iea.org/reports/renewables-2024/global-overview>>. Acesso em: 17 jul 2025.

LI, Q.; WANG, J.; ZHANG, H. A wind speed interval forecasting system based on constrained lower upper bound estimation and parallel feature selection. **Knowledge-based Systems**, v. 231, nov 2021.

LIAO, W.; *et al.* Ultra-short-term Interval Prediction of Wind Power Based on Graph Neural Network and Improved Bootstrap Technique. **Journal of Modern Power Systems and Clean Energy**, v. 11, n. 4, p. 1100–1114, jul 2023.

MA, T.; *et al.* Particle-swarm optimization of ensemble neural networks with negative correlation learning for forecasting short-term wind speed of wind farms in western China. **Information Sciences**, v. 505, p. 157–182, dez 2019.

MAHMOUD, T.; DONG, Z. Y.; MA, J. An advanced approach for optimal wind power generation prediction intervals by using self-adaptive evolutionary extreme learning machine. **Renewable Energy**, v. 126, p. 254–269, out 2018.

NAYAK, A. K.; *et al.* Probabilistic online learning framework for short-term wind power forecasting using ensemble bagging regression model. **Energy Conversion and Management**, v. 323, 2025.

- NGUINABÉ, J.; *et al.* Bootstrap prediction intervals for the long short term memory (LSTM) recurrent neural network. **Expert Systems with Applications**, v. 284, 2025.
- PARAMASIVAN, S. K.; LOPEZ, D. Forecasting of Wind Speed Using Feature Selection and Neural Networks. **International Journal Of Renewable Energy Research**, v. 6, n. 3, p. 833–837, 2016.
- PENG, T.; *et al.* Multi-step ahead wind speed forecasting using a hybrid model based on two-stage decomposition technique and AdaBoost-extreme learning machine. **Energy Conversion And Management**, v. 153, p. 589–602, dez 2017.
- PETROPOULOS, F.; *et al.* **Forecasting**: theory and practice. International Journal of Forecasting, v. 38, n. 3, p. 705–871, 1 Jul 2022. Acesso em: 21 jul 2025.
- REN, Y.; SUGANTHAN, P. N.; SRIKANTH, N. Ensemble methods for wind and solar power forecasting - A state-of-the-art review. **Renewable and Sustainable Energy Reviews**, v. 50, p. 82-91, out 2015.