



MODELOS HÍBRIDO E ENSEMBLE PARA PREVISÃO DE GERAÇÃO DE ENERGIA EÓLICA: UMA REVISÃO SISTEMÁTICA

HYBRID AND ENSEMBLE MODELS FOR WIND POWER GENERATION FORECASTING: A SYSTEMATIC REVIEW

Matheus Schrippe*  E-mail: mschrippe@alunos.utfpr.edu.br

Flavio Trojan*  E-mail: trojan@utfpr.edu.br

Fernando José Avancini Schenatto*  E-mail: schenatto@utfpr.edu.br

*Universidade Tecnológica Federal do Paraná (UTFPR), Pato Branco, Paraná, Brasil.

Resumo: A previsão da geração eólica é essencial para auxílio nas tomadas de decisões vinculadas a uso de fontes energéticas mais poluentes e/ou mais custosas. Este estudo realizou uma revisão de literatura sobre os métodos híbridos e ensemble para previsão de geração de energia eólica utilizando o Methodi Ordinatio 2.0. Foram selecionados 31 artigos no portfólio, em que avaliou-se a utilização de: pré-processamento, métodos de previsão e métrica de desempenho. Os artigos do portfólio demonstram uma preferência pelo pré-processamento dos dados, principalmente através dos métodos Empirical Mode Decomposition (EMD) e Variational Mode Decomposition (VMD) e suas variantes. Algo similar ocorreu com os métodos de previsão, em que foi encontrado uma variedade alta entre os métodos identificados. Já as métricas de desempenho, por mais que também haja uma variedade considerável, todos artigos possuíam a Mean Absolute Error (MAE) ou Root Mean Squared Error (RMSE). Dos artigos 70,97% são provenientes da China, e 29,03% do portfólio total provém da revista Energy.

Palavras-chave: Methodi Ordinatio 2.0. Previsão eólica. Híbrido. Ensemble.

Abstract: The forecasting of wind power generation is essential to support decision-making related to the use of less sustainable and/or costlier sources energy sources. This study conducted a literature review on hybrid and ensemble methods for wind power generation forecasting using the Methodi Ordinatio 2.0. A total of 31 articles were selected for the portfolio, where the use of preprocessing, forecasting methods, and performance metrics was evaluated. The articles in the portfolio show a preference for data preprocessing, mainly through Empirical Mode Decomposition (EMD), Variational Mode Decomposition (VMD), and their variants. A similar pattern was observed in the forecasting methods, a wide range of methods was identified. As for performance metrics, although there is also considerable variety, all articles employed either Mean Absolute Error (MAE) or Root Mean Squared Error (RMSE). Of the articles, 70.97% are from Chinese universities, and 29.03% of the total portfolio are from the journal Energy.

Keywords: Methodi Ordinatio 2.0. Wind forecast. Hybrid Ensemble.

1 INTRODUÇÃO

Conforme descrito por Kamer, Gieseke e Satzger (2013) e Ribeiro *et al.* (2022), a previsão de energia eólica desempenha um papel vital na sociedade devido sua importância econômica e ambiental, estando relacionadas a diminuição de emissões de dióxido de carbono, pois através dela, há o entendimento de quando utilizar as fontes de energia reserva, estas mais poluidoras.

Segundo Gao *et al.* (2023) a previsão precisa e estável da energia eólica pode aliviar os impactos incertos da geração causados por características não lineares da velocidade do vento. Mesmo com o consumo de combustível fóssil conhecido como uma fonte energética prejudicial ao planeta, Ritchie e Rosado (2024) apresentam que o Brasil com 8.700 kWh de consumo de combustível fóssil per capita apresenta um nível baixo em comparação com uma média global 17.208 kWh, com os dados brasileiros sofrendo um decréscimo desde 2014.

A realização de Revisões de Literatura ajuda os pesquisadores a encontrarem lacunas na literatura, além de fundamentar sua pesquisa, pois é possível avaliar as metodologias empregadas por outros autores, podendo servir de base para novos estudos. Com métodos de previsão mais eficientes surgindo, torna-se útil realizar uma RSL para serem aplicados. O método escolhido para a revisão foi uma variante do método ProKnow-C, denominado Methodi Ordinatio 2.0, trata-se a segunda versão do método, essa versão possibilita alterar os pesos de cada um dos critérios, sendo eles: número de citações, fator de impacto (do meio de publicação) e ano de publicação. O método cria um ranking (RankIn) para classificar os artigos através. O presente trabalho mantém a versão original do método com peso como 10 para os três fatores. Para maior aderência ao trabalho, utilizou-se 3 eixos temáticos, sendo eles: energia eólica, previsão e o método utilizado (ensemble ou híbrido).

2 DESENVOLVIMENTO

No presente tópico será abordado as etapas da implementação do Methodi Ordinatio 2.0.

2.1 Methodi Ordinatio 2.0

Após o levantamento dos dados, utilizou-se a metodologia Methodi Ordinatio 2.0 (M.O.) de Pagani *et al.* (2023). escolha reforçada pela afirmação de Oliveira (2023) o M.O. possui o índice InOrdinatio que resulta em um ranking dos artigos, ponderando os artigos mesmo que seja mais recente, podendo competir no ranking com artigos mais antigos e mais citados, permitindo um aprimoramento na análise dos temas correlacionados. As etapas seguidas estão descritas a seguir:

Etapa 1: com o intuito de pesquisar a previsão de energia eólica utilizando métodos híbridos, os eixos temáticos foram: energia eólica, previsão de demanda e métodos híbridos.

Etapa 2: foram realizadas buscas exploratórias nas bases Scopus, WebofScience e Scielo. Como não foi encontrado nenhum artigo que contivesse os três eixos temáticos na Scielo, essa base foi excluída. A string de busca foi "wind energy" OR "wind power" OR "eolic energy" AND "forecast" OR "foresight" OR "prospecti" OR "time series" AND "ensemble" or "hybrid" com limitação de linha temporal (2019 a 2024). Desta forma totalizando 1.338 artigos na iniciação do método, com pesquisas realizadas no dia 24 de maio de 2024. Com a base WebofScience utilizando apenas as palavras-chaves, sem mais filtros para as pesquisas. Diferente da base Scopus, em que se refinou mais, resultando em apenas artigos que possuísse as buscas em: título do artigo, abstrato ou palavra-chave.

Etapa 3: conforme as buscas preliminares, a sintaxe da busca final ficou definido conforme a Tabela 1:

Tabela 1 - Resultados das buscas nas bases de pesquisas

String de busca	Scopus	Web of Science	Resultado bruto
"wind energy" OR "wind power" OR "eolic energy" AND "forecast" OR "foresight" OR "prospecti" OR "time series" AND "ensemble" or "hybrid".	866	472	1338

Fonte: autoria própria (2025).

Etapa 4: as buscas definitivas nas bases resultaram num total bruto de 1338 artigos.

Etapa 5: Nesta etapa, os dados foram filtrados utilizando o software JabRef, conforme os seguintes critérios: (I) eliminação artigos duplicados, (II) artigos que não sejam publicações em periódicos são retiradas, (III) artigos que não possuem aderência com o tema, ou a utilização dos métodos não híbridos, foram eliminados.

Etapa 6: É feita a identificação de Fator de Impacto (FI) dos periódicos, ano de publicação e citações. O FI dos periódicos que publicaram os artigos foi obtido por meio do site Scopus Source List.

Etapa 7: Os dados são exportados para a ferramenta RankIn (Pagani *et al.* 2023), que aplica a equação InOrdinatio (Pagani *et al.* 2015) o ranqueamento é possuído através da aplicação da Fórmula 1:

$$InOrdinatio = \left\{ \left[\Delta \cdot (IF) - \left[\lambda \cdot \left(\frac{ResearchYear - PubYear}{CitedHalfLife} \right) \right] \right] + \Omega \cdot \left[\frac{Ci}{(ResearchYear + 1) - PubYear} \right] \right\} \quad (1)$$

Os valores de Δ , λ , Ω variam entre 0 e 10, influenciando respectivamente no impacto da importância do fator de impacto (FI), relevância do ano ser mais recente e citações. Todos os parâmetros se mantiveram em 10.

Na aplicação do método InOrdinatio 85,52% do ranking correspondiam a 37 dos 67 artigos, sendo estes os escolhidos para o portfólio do artigo. O motivo da escolha de utilizar apenas os 37 primeiros, foi o fato de haver uma diferença significativa entre a pontuação do 37º do ranking com o 38º. Outrossim, os 30 artigos sobranes totalizavam apenas 14,48%.

Etapa 8: Os artigos são adquiridos em íntegra para posterior leitura completa dos 36 artigos selecionados.

Etapa 9: Após a leitura de todos os artigos, verificou-se uma não aderência e exigindo outra seleção, retirando mais 6 artigos, agora com 77,17% do ranking, com o portfólio final de 31 artigos.

Os processos de filtragem aplicados estão descritos na Tabela 2, e resultaram para o portfólio final um total de 31 artigos:

Tabela 2 – Resultados da aplicação do método

Filtragem dos documentos	Número de Artigos
Total de documentos coletados	1338
Eliminação de duplicatas	336
Eliminação por tipo de documento	152
Eliminação por leitura	789
InOrdinatio	30
Total de artigos eliminados	1307
Total de artigos do portfólio	31

Fonte: A autoria própria (2025).

Após a aplicação do método, a Tabela 3 expõe-se os artigos encontrados e sua respectiva posição após a aplicação do InOrdinatio:

Tabela 3 – Artigos da revisão selecionados pelo InOrdinatio

Autores	Artigo	Ano	InOrdinatio	Ranking
Qian, Z., <i>et al.</i>	A review and discussion of decomposition-based hybrid models for wind energy forecasting applications	2019	714,09	1
Zheng, J., <i>et al.</i>	A hybrid framework for forecasting power generation of multiple renewable energy sources	2023	658,68	2
Xiong, J., <i>et al.</i>	A dual-scale deep learning model based on ELM-BiLSTM and improved reptile search algorithm for wind power prediction	2023	542,68	3
da Silva, R.G., <i>et al.</i>	A novel decomposition-ensemble learning framework for multi-step ahead wind energy forecasting	2021	487,55	4
Yang, W., <i>et al.</i>	Hybrid wind energy forecasting and analysis system based on divide and conquer scheme: A case study in China	2019	379,75	5
Shi, X., <i>et al.</i>	A fuzzy time series forecasting model with both accuracy and interpretability is used to forecast wind power	2024	284,00	6
Liu, X., <i>et al.</i>	A Bayesian Deep Learning-based Wind Power Prediction Model Considering the Whole Process of Blade Icing and De-icing	2024	213,00	7
Wang, J., <i>et al.</i>	A novel wind power prediction model improved with feature enhancement and autoregressive error compensation	2023	211,68	8

Jung, C. and Schindler, D.	Comprehensive validation of 68 wind speed models highlights the benefits of ensemble approaches	2023	198,68	9
Casciaro, G., <i>et al.</i>	Novel strategies of Ensemble Model Output Statistics (EMOS) for calibrating wind speed/power forecasts	2022	197,37	10
Wang, H., <i>et al.</i>	A novel multi-layer stacking ensemble wind power prediction model under Tensorflow deep learning framework considering feature enhancement and data hierarchy processing	2024	194,00	11
Hanifi, S., <i>et al.</i>	Offshore wind power forecasting based on WPD and optimised deep learning	2023	184,68	12
Karijadi, I., Chou, S.-Y. E Dewabharata, A.	Wind power forecasting based on hybrid CEEMDAN-EWT deep learning method	2023	184,68	13
Donadio, L., Fang, J. and Porté-Agel, F.	Numerical weather prediction and artificial neural network coupling for wind energy forecast	2021	181,05	14
Hou, G., Wang, J. and Fan, Y.	Wind power forecasting method of large-scale wind turbine clusters based on DBSCAN clustering and an enhanced hunter-prey optimization algorithm	2024	180,00	15
Wu, Z., <i>et al.</i>	Explainable temporal dependence in multi-step wind power forecast via decomposition based chain echo state networks	2023	172,68	16
Chang, Y., <i>et al.</i>	A Hybrid Model for Long-Term Wind Power Forecasting Utilizing NWP Subsequence Correction and Multi-Scale Deep Learning Regression Methods	2024	171,00	17
Mirza, A.F., <i>et al.</i>	Quantile-transformed multi-attention residual framework (QT-MARF) for medium-term PV and wind power prediction	2024	166,00	18
Hou, G., <i>et al.</i>	A novel wind power deterministic and interval prediction framework based on the critic weight method, improved northern goshawk optimization, and kernel density estimation	2024	146,00	19
Zhong, L., Wu, P. e Pei, M.	Wind power generation prediction during the COVID-19 epidemic based on novel hybrid deep learning techniques	2024	146,00	20
Zhang, D., <i>et al.</i>	A novel spatio-temporal wind speed forecasting method based on the microscale meteorological model and a hybrid deep learning model	2024	144,00	21
Dai, J. e Fu, L.-h.	A wind speed forecasting model using nonlinear auto-regressive model optimized by the hybrid chaos-cloud salp swarm algorithm	2024	134,00	22

Zhang, Y., <i>et al.</i>	Ensemble optimization approach based on hybrid mode decomposition and intelligent technology for wind power prediction system	2024	134,00	23
Yuzgec, U., Dokur, E. e Balci, M.	A novel hybrid model based on Empirical Mode Decomposition and Echo State Network for wind power forecasting	2024	134,00	24
Meng, A., <i>et al.</i>	An adaptive distribution-matched recurrent network for wind power prediction using time-series distribution period division	2024	134,00	25
Aslam, M., Kim, J.-S. e Jung, J.	Multi-step ahead wind power forecasting based on dual-attention mechanism	2023	128,68	26
Wang, J., Tang, X. e Jiang, W.	A deterministic and probabilistic hybrid model for wind power forecasting based improved feature screening and optimal Gaussian mixed kernel function	2024	122,00	27
Ai, C., <i>et al.</i>	Chaotic time series wind power interval prediction based on quadratic decomposition and intelligent optimization algorithm	2023	107,68	28
Li, G., <i>et al.</i>	Hybrid forecasting system considering the influence of seasonal factors under energy sustainable development goals	2023	106,68	29
Ribeiro, M.H.D.M., <i>et al.</i>	Variational mode decomposition and bagging extreme learning machine with multi-objective optimization for wind power forecasting	2024	98,00	30
Gao, Y., <i>et al.</i>	Multi-step wind speed prediction based on LSSVM combined with ESMD and fractional-order beetle swarm optimization	2023	88,68	31

Fonte: Aatoria própria (2025).

2.2 Pré-processamento

A técnica em questão refere-se à decomposição dos dados originais das séries temporais em subséries, permitindo assim, encontrar entre diversos aspectos, os que mais influenciam no comportamento da série temporal. Conforme Qian *et al.* (2019) os métodos de decomposição que são utilizados para maior precisão na previsão, após a decomposição os métodos tendem a seguir três estruturas, sendo elas: a primeira estrutura é a previsão de cada subsérie criada utilizando modelos diferentes. Já a segunda estrutura, são decompostas ainda mais em um conjunto de subséries mais estacionárias usando o método de decomposição secundária, desta forma, deixando-a ainda mais simples. As duas primeiras estruturas juntam seus dados de

cada subsérie para formação do resultado final. Modelos estes diferentes da estrutura 3, nela as subséries são agrupadas e é feita apenas uma previsão.

Há uma variedade grande de subséries que podem ser criadas através dos dados iniciais, desta forma, sendo possível verificar a correlação com variáveis potencialmente influentes na série. Houve uma grande variedade de modelos, em especial Variational Mode Decomposition (VMD) e Empirical Mode Decomposition (EMD), tanto os modelos originais quanto diversas variantes, foram os mais recorrentes. Outras técnicas de pré-processamentos que estiveram no portfólio foram: Wavelet, Extreme-point Symmetric Mode Decomposition (ESMD), técnica híbrida de quartis e fuzzy C-means (FCM), Density-Based Spatial Clustering of Applications with Noise (DBSCAN) e Multi-head attention (MHA). Alguns artigos não utilizaram técnicas de pré-processamento dos dados.

2.3 Previsão da energia eólica

Segundo Pellegrini e Fogliatto (2001), séries temporais de demandas referem-se aos dados que registram a variação dessa variável ao longo do tempo. A literatura especializada oferece diversos métodos quantitativos para a modelagem de séries temporais. Morettin e Tolo (2018) afirmam que a maioria dos métodos de previsão de demanda presume que os dados passados contêm padrões de comportamento que podem ser analisados em séries temporais. Sousa *et al.* (2021) destacam que as séries temporais são valiosas para observar fenômenos em diversas áreas, permitindo previsões para períodos futuros. Apresentando tendência, ciclo, sazonalidade e irregularidade, sendo o último quaisquer dados que não se encaixam na tendência, ciclo ou sazonalidade.

Como há uma grande quantidade de métodos no portfólio, fez-se necessário o quadro 1 contendo todos os métodos utilizados para a previsão e decomposição dos dados.

Quadro 1 – Métodos presentes no portfólio

Abreviação	Nomenclatura	Abreviação	Nomenclatura
A-LSTM	Long Short-Term Memory	IWI	Intelligent weighted integration
ABC	Artificial Bee Colony	KDE	Kernel density estimation

ABLAR	AM-BiLSTM-ARIMA	KNN	k-Nearest Neighbor
ADMGRU	Adaptive distribution-matched GRU	LSTM	Long Short-Term Memory
AGRU	Attention mechanism GRU	LSSVM	Least squares support vector machine
AM	Attention Mechanism	MARF	Multi-Attention Residual Framework
AR	Auto-regressive	MHA	Multi-head attention
ARIMA	Autoregressive Integrated Moving Average Model	MLP	Multi-layer perceptron network
BDL-WPP	Bayesian deep learning-based WPP	MSSA	Multi-objective Salp Swarm Algorithm
BiLSTM	Bidirectional Long Short-Term Memory	NARX	Nonlinear auto-regressive model with exogenous inputs
BSO	Beetle swarm optimization	ND	Normal distribution
CC-SSA	Chaos-cloud salp swarm algorithm	NWP	Numerical weather prediction
CEEMD	Complementary Ensemble Empirical Mode Decomposition	OVMD	Optimal variational mode decomposition
CEEMDAN	Complete Ensemble Empirical Mode Decomposition with Adaptive Noise	PFC	Polynomial fitting of wind speed and power curves.
CNN	Convolutional Neural Network	PLS	Partial Least Squared Regression
Cubist	Cubist Regression	P(r)	Pearson correlation coefficient
DBSCAN	Density-based spatial clustering of applications with noise	PE	Permutation entropy
DCESN	Deep-chain echo state network	PRP	Probability range prediction
DTW	Dynamic time warping	PSO	Particle swarm optimization
ELM	Extreme Learning Machine	QT	Quantile-Transformed
EMD	Empirical mode decomposition	RIDGE	Ridge Regression
EMOS	Ensemble Model Output Statistics	RF	Random Forest
ENHPO	Enhanced hunter-prey optimization algorithm	RFE	Recursive feature elimination
EPS	Ensemble Prediction System	SDA	Subsequence division and alignment.
ESMD	Extreme-point symmetric mode decomposition	SE	Sample Entropy
ESN	Echo-state network	SLG-AHA	Simplified Linguistic Groups e artificial hummingbird algorithm
EWT	Empirical Wavelet Transform	STACK	Stacking-ensemble learning
FCM	Fuzzy Cmeans	SVD	Singular Value Decomposition

FENSAP-ICE	Finite Element Navier-Stokes Analysis Package e Ice Accretion and Control Environment	SVM	Support vector machine
FO	Fractional-order	SVR	Support Vector Regression
FTS	Fuzzy Time Series	TCN	Temporal convolutional network
GPR	Gaussian Process Regression	TSDPD	Time-series distribution period division
GRU	Gated Recurrent Unit	VMD	Variational Mode Decomposition
HMD	Hybrid modal decomposition	VB-GRU	Variational Bayesian gated recurrent unit
ICEEMDAN	Improved complete ensemble empirical mode decomposition with adaptive noise	VBN	Variational Bayesian neuron
IFS	Improved feature screening	WPD	Wavelet packet decomposition
INGO	Improved northern goshawk optimization	WRF	Weather Research and Forecasting Model
IRSA	Improved Reptile Search Algorithm	XGBoost	Extreme gradient boosting

Fonte: Aatoria própria (2025).

2.4 Métricas de desempenho

Para aferir a performance dos métodos, utiliza-se métodos de desempenho que verificam o erro causado pelo método, entre o valor previsto e o valor real. Como os métodos trabalham de formas diferentes, é válido a utilização de mais de uma medida de desempenho para comparar entre os outros métodos.

Dada a grande quantidade de métricas para avaliar e treinar os modelos, o quadro 2 traz a abreviação e a nomenclatura destas medidas.

Quadro 2 – Métricas de desempenho

Abreviação	Nomenclatura
AIC	Akaike Information Criterion
BIC	Bayesian information criterion
CI	Confidence Index
CRPS	Continuous Ranked Probability Score
DM	Diebold-Mariano
ESD	Error Standard Deviation
GRD	Grey Relation Degree

MAE	Mean Absolute Error
MdAPE	Median Absolute Percentage Error
MAPE	Mean Absolute Percentage Error
MedAE	Median Absolute Error
ME1	Maximum Error
ME2	Mean Error
MSE	Mean Squared Error
NRMSE	Normalized Root Mean Squared Error
PCC	Pearson's Correlation Coefficient
PI	Prediction interval
PICP	Converge Probability
PL	Pinball Loss
PINAW	PI-normalized average width
R2	Coefficient of Determination
r	Correlation Coefficient
RMSE	Root Mean Squared Error
U1	Theil U statistic 1
U2	Theil U statistic 2
WS	Winkler score

Fonte: Autoria própria (2025).

Dada a grande quantidade de métricas para avaliar e treinar os modelos, a tabela 5 traz a abreviação e a nomenclatura destas medidas.


2.5 Dados do portfólio

No presente tópico, serão apresentados os resultados das pesquisas realizadas, com: ano das publicações, países dos artigos e revistas presentes no portfólio.

2.5.1 Anos das publicações

Através dos resultados da revisão bibliográfica, o gráfico 1 representa os 31 artigos do portfólio organizado por ano:

Gráfico 1 - Publicações por ano



Fonte: Autoria Própria (2025).

Nota-se uma grande quantidade sendo proveniente do ano de 2024 e 2023, correspondendo a 83,87% do total. A escolha de publicações atuais é impulsionada por um dos pesos na aplicação do InOdinatio, quanto mais recente o artigo, mais peso respectivamente recebe.

2.5.2 Países representantes

A representação do portfólio total de 31 artigos inclui diversos países, conforme a vinculação institucional dos autores. O país atribuído a cada artigo corresponde à localização da universidade com a qual o(s) autor(es) estava(m) vinculado(s) no momento da publicação. Nos casos em que havia múltiplos autores filiados a diferentes universidades e países, foi considerado como país representativo daquele artigo aquele com maior número de autores afiliados. A tabela 6 demonstra a quantidade de publicações por países vinculados:

Tabela 4 – Relação de países no portfólio

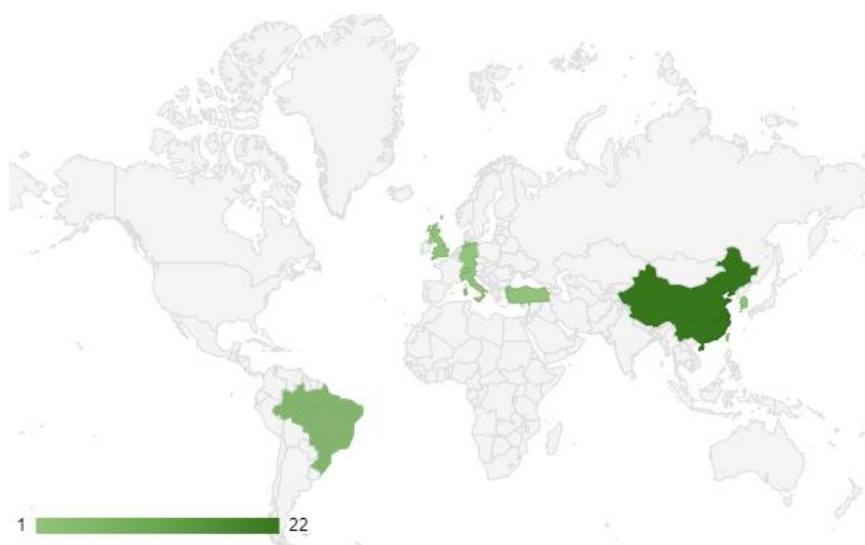
País	Quantidade
China	22
Brasil	2
Alemanha	1

Coreia do Sul	1
Itália	1
Reino Unido	1
Suíça	1
Taiwan	1
Turquia	1

Fonte: Autoria própria (2025).

Nota-se a importância da previsão de energia eólica no continente asiático, principalmente na China, país que detém a maior quantidade de estudos na área com 22, o segundo é o Brasil, com 2, e os demais com 1. Demonstrando o enorme interesse dos pesquisadores chineses na área. A imagem 1 ilustra como está espalhado pelo mundo as publicações:

Figura 1 – Mapa dos países e citações no portfólio



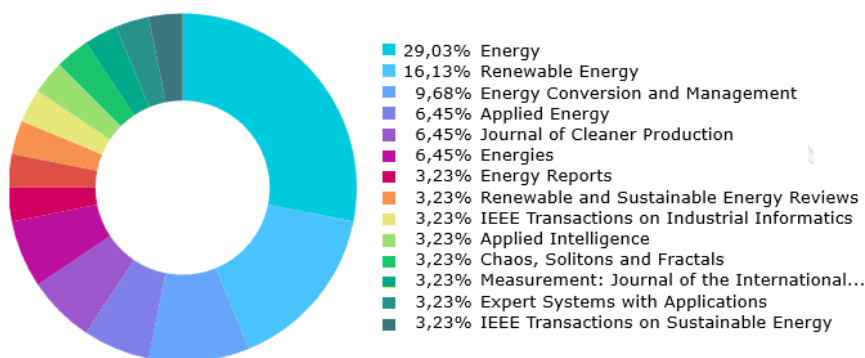
Fonte: Autoria Própria (2025).

A região da Ásia é a com mais publicações na área, com 25 dos 31 ou 80,65% (Turquia foi contabilizada na Ásia, pois maior parte do país se encontra na Anatólia), impulsionada pela China, que sozinha detém 70,97% das publicações. O segundo continente com mais publicações é a Europa, com 4, ou 12,90%. E o terceiro, e último, com mais publicações é a América, com 2, correspondentes a 6,45%, ambos do Brasil.

2.5.3 Participação das revistas no portfólio

Com a criação do portfólio de artigos, revistas com maior fator de impacto tendem a destacar-se com maior quantidade de artigos no próprio, pois, um dos fatores utilizado na Rankin do Methodi Ordinatio 2.0, trata-se do fator de impacto. A imagem 2 traz consigo a quantidade de artigos publicados nas respectivas revistas:

Figura 2 – Quantidade de publicações por revista



Fonte: Autoria própria (2025).

A revista Energy possui a maior participação com 9 artigos, seguida pela Renewable Energy com 5 e Energy Conversion and Management com 3, juntas correspondem a 54,84% do total. Com 2, há o Journal of Applied Energy, Cleaner Production e Energies. As demais possuem apenas uma publicação.

3 CONCLUSÕES

A análise dos artigos evidenciou a ampla diversidade de métodos aplicados à previsão de velocidade, direção do vento e geração de energia eólica. Demonstrando não haver um modelo universalmente superior. Contudo, observou-se uma tendência à utilização de técnicas de decomposição, especialmente EMD e VMD e suas variantes, que contribuem para reduzir ruídos e simplificar as séries, resultando em previsões mais robustas.

Os métodos híbridos e ensemble mostraram desempenho superior em relação aos modelos individuais, encontrando valores mais próximos aos valores das séries temporais, algo observado em todos os artigos do portfólio. Apesar disso, alguns

trabalhos apresentaram elevado custo computacional, desta forma, podendo limitar a aplicação prática em contextos com infraestrutura computacional restrita.

A grande variedade de medidas de desempenho também é notória, mas tendem a manter um padrão na escolha de MAE e RMSE. Enquanto o MAE realiza uma média simples dos erros, o RMSE pune mais os pontos considerados outliers. Evidenciando, por mais que haja uma grande quantidade de medidas, as mais tradicionais tendem a suceder em todas as pesquisas.

Este estudo evidencia que a previsão de geração eólica continua sendo um campo em rápida evolução, marcado por diversidade metodológica e forte concentração de pesquisas na Ásia, em especial na China. Para pesquisas futuras, recomenda-se ampliar os eixos temáticos e palavras-chave, bem como explorar técnicas específicas de pré-processamento e previsão, de modo a identificar novos caminhos para modelos mais precisos e aplicáveis em larga escala.

REFERÊNCIAS

- AI, C. *et al.* Chaotic time series wind power interval prediction based on quadratic decomposition and intelligent optimization algorithm. **Chaos, Solitons and Fractals**, v. 177, 114222, 2023.
- ASLAM, M. KIM, J.-S. JUNG, J. Multi-step ahead wind power forecasting based on dual-attention mechanism. **Energy Reports**, v. 9, p. 239-251, 2023.
- CASCIARO, G. *et al.* Novel strategies of Ensemble Model Output Statistics (EMOS) for calibrating wind speed/power forecasts. **Energy Conversion and Management**, v. 271, 116297, 2022.
- CHANG, Y. *et al.* A Hybrid Model for Long-Term Wind Power Forecasting Utilizing NWP Subsequence Correction and Multi-Scale Deep Learning Regression Methods. **IEEE TRANSACTIONS ON SUSTAINABLE ENERGY**, vol. 15, 1, 2024.
- DAI, J. FU, L. A wind speed forecasting model using nonlinear auto-regressive model optimized by the hybrid chaos-cloud salp swarm algorithm. **Energy**, v. 298, 131332, 2024.
- DONADIO, L. FANG, J. PORTÉ-AGEL, F. Numerical Weather Prediction and Artificial Neural Network Coupling for Wind Energy Forecast. **Energies**, v. 14, 338, 2021.
- GAO, Y. *et al.* Multi-step wind speed prediction based on LSSVM combined with ESMD and fractional-order beetle swarm optimization. **Energy Reports**, v. 9, p. 6114-6134, 2023.

HANIFI, S. *et al.* Offshore wind power forecasting based on WPD and optimised deep learning methods. **Renewable Energy**, v. 218, 119241, 2023.

HOU, G. *et al.* A novel wind power deterministic and interval prediction framework based on the critic weight method, improved northern goshawk optimization, and kernel density estimation. **Renewable Energy**, v. 222, 119863, 2024.

HOU, G. WANG, J. FAN, Y. Wind power forecasting method of large-scale wind turbine clusters based on DBSCAN clustering and an enhanced hunter-prey optimization algorithm. **Energy Conversion and Management**, v. 307, 118341, 2024.

JUNG, C. SCHINDLER, D. Comprehensive validation of 68 wind speed models highlights the benefits of ensemble approaches. **Energy Conversion and Management**, v. 286, 117012, 2023.

KARIJADI, I. *et al.* Wind power forecasting based on hybrid CEEMDAN-EWT deep learning method. **Renewable Energy**, v. 218, 119357, 2023.

LI, G. *et al.* Hybrid forecasting system considering the influence of seasonal factors under energy sustainable development goals. **Measurement**, v. 211, 112607, 2023.

LIU, X. *et al.* A Bayesian Deep Learning-based Wind Power Prediction Model Considering the Whole Process of Blade Icing and De-icing. **IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS**, v. 20, p 1-11, 2024.

MENG, A. *et al.* An adaptive distribution-matched recurrent network for wind power prediction using time-series distribution period division. **Energy**, v. 299, 131383, 2024.

MIRZA, A. F. *et al.* Quantile-transformed multi-attention residual framework (QT-MARF) for medium-term PV and wind power prediction. **Renewable Energy**, v. 220, 119604, 2024.

MORETTIN, P. A.; TOLOI, C. M. C. Modelos de suavização exponencial. **Análise de Séries Temporais: Modelos lineares univariados**. São Paulo: Edgard Blucher, 2018.

OLIVEIRA, M. S. de. *Et al.* Integrated data envelopment analysis, multi-criteria decision making, and cluster analysis methods: Trends and perspectives. **Decision Analytics Journal**, v. 8, 100271, 2023.

PAGANI, R.N. KOVALESKI, J.L. RESENDE, L.M. Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. **Scientometrics**, v.105, p. 2109-2135, 2015.

PAGANI, R.N. *et al.* Methodi Ordinatio 2.0: revisited under statistical estimation, and presenting Flinder and RankIn. **Quality & Quantity**, v. 57, p. 4563-4602, 2023.

PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda** - Técnicas e Estudo de Caso. *Produção*, 11, 1, 2001.

QIAN, Z. *et al.* A review and discussion of decomposition-based hybrid models for wind energy forecasting applications. **Applied Energy**, v. 235, p. 939-953, 2019.

RIBEIRO, M. H. D. M. Variational mode decomposition and bagging extreme learning machine with multi-objective optimization for wind power forecasting. *Applied Intelligence*, v. 54, p. 3119-3134, 2024.

SHI, X. WANG, J. ZHANG, B. A fuzzy time series forecasting model with both accuracy and interpretability is used to forecast wind power. **Applied Energy**, v. 335, 122015, 2024.

SOUSA, A. R. D. S. *et al.* **ANÁLISE DE SÉRIES TEMPORAIS**. Porto Alegre: SAGAH, 2021.

XIONG, J. *et al.* A dual-scale deep learning model based on ELM-BiLSTM and improved reptile search algorithm for wind power prediction. **Energy**, v. 266, 126419, 2023.

YUZGEC, U. DOKUR, E. BALCIC, M. A novel hybrid model based on Empirical Mode Decomposition and Echo State Network for wind power forecasting. **Energy**, v. 300, 131546, 2024.

WANG, H. *et al.* A novel multi-layer stacking ensemble wind power prediction model under Tensorflow deep learning framework considering feature enhancement and data hierarchy processing. **Energy**, v. 286, 129409, 2024.

WANG, J. *et al.* A novel wind power prediction model improved with feature enhancement and autoregressive error compensation. **Journal of Cleaner Production**, v. 420, 138386, 2023.

Wang, J. TANG, T. D. JIANG, W. Y. A deterministic and probabilistic hybrid model for wind power forecasting based improved feature screening and optimal Gaussian mixed kernel function. **Expert Systems with Applications**, v. 251, 123965, 2024.

WU, Z. *et al.* Explainable temporal dependence in multi-step wind power forecast via decomposition based chain echo state networks. *Energy*, v. 270, 126906, 2023.

YANG, W. *et al.* Hybrid wind energy forecasting and analysis system based on divide and conquer scheme: A case study in China. **Journal of Cleaner Production**, v. 222, p. 942-959, 2019.

ZHANG, D. *et al.* A novel spatio-temporal wind speed forecasting method based on the microscale meteorological model and a hybrid deep learning model. **Energy**, v. 288, 129823, 2024.

ZHANG, Y. *et al.* Ensemble optimization approach based on hybrid mode decomposition and intelligent technology for wind power prediction system. **Energy**, v. 292, 130492, 2024.

ZHENG, J. *et al.* A hybrid framework for forecasting power generation of multiple renewable energy sources. **Renewable and Sustainable Energy Reviews**, v. 172, 110346, 2023.

Biografia do(s) autor(es)

Matheus Schrippe

Mestrando em Engenharia de Produção e Sistemas na Universidade Tecnológica Federal do Paraná (UTFPR) de Pato Branco. Pós-graduado em Engenharia de Segurança do Trabalho pela Descomplica e Engenheiro de Produção pela Universidade Tecnológica Federal do Paraná (UTFPR) de Medianeira. Previsão de demanda de geração eólica, utilização de modelos híbridos e ensemble, segurança do trabalho, ergonomia e mercado financeiro.

Flavio Trojan

Pós-doutorado na Universidade Federal de Pernambuco - PPGE, Doutor em Engenharia de Produção pela UFPE - Universidade Federal de Pernambuco - PPGE. Mestre em Engenharia de Produção pela UTFPR - PPGE, Especialização em Gestão Industrial pelo CEFET-PR, Graduação em Ciências Econômicas pela Universidade Estadual de Ponta Grossa- UEPG, Graduação em Tecnologia Eletrônica (Automação Industrial) pelo CEFET-PR. É Professor Titular da UTFPR nos cursos superiores de Engenharia Elétrica e Tecnologia em Automação Industrial. Professor permanente no Programa de pós-graduação em Engenharia de Produção (PPGEP - Campus Ponta Grossa) e professor permanente no Programa de pós-graduação em Engenharia de Produção e Sistemas (PPGEPS - Campus Pato Branco). Editor Chefe da Revista Gestão Industrial. Atuou como mantenedor do Sistema de Automação da Companhia de Saneamento do Paraná e foi Professor Colaborador na Universidade Estadual de Ponta Grossa - UEPG. Tem experiência na área de Engenharia de Produção com os temas: Pesquisa Operacional, Apoio a Decisão e Decisão Multicritério e Engenharia Elétrica, com ênfase em Automação Industrial, atuando principalmente nos seguintes temas: Informática Industrial, Automação, Sistemas Supervisórios, Controle de Processos, Saneamento Básico, Gestão da Manutenção, Tecnologia da Informação e ainda experiência em Economia com os temas: Crescimento Econômico Brasileiro, Economia Matemática e Estatística Econômica.

Fernando José Avancini Schenatto

Doutor em Engenharia de Produção na Universidade Federal de Santa Catarina, Mestre em Engenharia de Produção na Universidade Federal de Santa Catarina, Especialização em Educação Matemática Fundação Comunitária Educacional e Cultural Patrocinio, Graduação em Engenharia Elétrica Universidade Católica de Pelotas. Professor titular da Universidade Tecnológica Federal do Paraná. Tem experiência na área de Engenharia de Produção, com ênfase em Gestão da Inovação Tecnológica, atuando principalmente nos seguintes temas: gestão da inovação; gestão de tecnologia; estratégia tecnológica; prospectiva estratégica; arranjos produtivos locais; e incubadoras de empresas.



Artigo recebido em: 16/06/2025 e aceito para publicação em: 26/08/2025

DOI: <https://doi.org/10.14488/1676-1901.v26i2.5634>