



ConBRepro

XV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

PREVISÃO INTERVALAR PARA DADOS DE ENERGIAS RENOVÁVEIS COMBINADAS COM APRENDIZADO PROFUNDO E INTELIGÊNCIA ARTIFICIAL GENERATIVA: UM ESTUDO DE CASO PARA PREVISÃO DA VELOCIDADE DO VENTO EM CAMBARÁ DO SUL, RIO GRANDE DO SUL

Vinicius Bortolini

Universidade Tecnológica Federal do Paraná – Pato Branco, Brasil

Jhonnata Novaes Pires

Universidade Tecnológica Federal do Paraná – Pato Branco, Brasil

Matheus Henrique Dal Molin Ribeiro

Universidade Tecnológica Federal do Paraná – Pato Branco, Brasil

Resumo: Este estudo aborda a previsão intervalar da velocidade do vento, aspecto essencial para a operação segura e eficiente de sistemas de geração eólica. A quantificação da incerteza é indispensável em aplicações energéticas, pois permite decisões mais robustas frente à variabilidade natural do vento. Nesse contexto, a pesquisa analisa o desafio de fornecer não apenas previsões pontuais, mas também intervalares, aumentando a confiabilidade dos modelos aplicados a fontes renováveis. O objetivo é avaliar diferentes técnicas estatísticas e de aprendizado de máquina para aprimorar a qualidade e a calibração dos intervalos de previsão. Foram testados métodos de reamostragem nos resíduos (do inglês, Bootstrapped), previsão Gaussiana (do inglês, Gaussian Forecasting), previsão conformal (do inglês, Conformal Prediction) e regressão quantílica (do inglês, Quantile Regression), todos baseados em uma rede recorrente de memória de longo prazo (do inglês, Long Short-Term Memory, LSTM) e também o modelo pré-treinado TimeGPT, aplicado a dados de uma estação meteorológica em Cambará do Sul, no sul do Brasil, considerando horizontes de até três passos à frente. Os resultados indicaram que a previsão conformal com LSTM apresentou o melhor desempenho intervalar, com proporção de cobertura preditiva (do inglês, Predictive Interval Coverage Probability, PICP) de 0,961. Na previsão pontual, a regressão quantílica obteve o menor erro absoluto médio (do inglês, Mean Absolute Error, MAE), de 0,714, enquanto o TimeGPT demonstrou robustez em três passos. Conclui-se que a previsão conformal é eficaz na geração de intervalos bem calibrados, contribuindo para decisões mais seguras em energia renovável.

Palavras-chave: Previsão intervalar, Previsão conformal, Séries temporais, Velocidade do vento, Energia eólica.

Interval Wind Speed Forecasting for Wind Farms in Rio Grande do Sul Using Traditional and Advanced Models.

Abstract: This study addresses interval forecasting of wind speed, an essential aspect for the safe and efficient operation of wind power systems. Quantifying forecast uncertainty is indispensable in

energy applications, as it enables more robust decision-making under the natural variability of wind. In this context, the research tackles the challenge of providing not only point forecasts but also interval forecasts, thereby increasing the reliability of models applied to renewable energy sources. The objective is to evaluate different statistical and machine learning techniques to improve the quality and calibration of prediction intervals. The methods tested included residual resampling (Bootstrapped), Gaussian Forecasting, Conformal Prediction, and Quantile Regression, all based on a recurrent Long Short-Term Memory network, as well as the pre-trained TimeGPT model, applied to data from a meteorological station in Cambará do Sul, southern Brazil, considering horizons of up to three steps ahead. The results showed that Conformal Prediction with LSTM achieved the best interval forecasting performance, with a Predictive Interval Coverage Probability (PICP) of 0.961. For point forecasting, Quantile Regression obtained the lowest Mean Absolute Error (MAE) of 0.714, while TimeGPT demonstrated robustness over three steps. It is concluded that Conformal Prediction is effective in generating well-calibrated intervals, contributing to safer and more reliable decision-making in renewable energy applications.

Keywords: Interval forecasting, Conformal Prediction, Time series, Wind speed, Wind energy.

1. Introdução

A energia eólica vem se consolidando como uma das principais fontes alternativas para a geração de eletricidade no mundo, por se tratar de uma solução limpa, renovável e ambientalmente sustentável (McKENNA et al., 2024). Essa matriz energética apresenta vantagens significativas, como a ausência de emissões de gases poluentes e a contribuição direta para a mitigação dos impactos causados pelo uso intensivo de combustíveis fósseis (MSIGWA et al., 2022). No entanto, a expansão e operação de parques eólicos ainda enfrentam desafios técnicos consideráveis, principalmente no que diz respeito à variabilidade dos ventos — fator que impacta diretamente na eficiência da geração e na estabilidade do fornecimento energético (LOZA et al., 2024).

Além disso, a necessidade de infraestrutura em regiões remotas e a dependência de previsões meteorológicas precisas para o planejamento e otimização da produção impõem barreiras econômicas e operacionais importantes (CLIFTON et al., 2022). Nesse contexto, a utilização de técnicas avançadas de previsão da velocidade do vento torna-se essencial para apoiar decisões estratégicas no setor energético, como a seleção de áreas com maior potencial de geração contínua (MARUTHI et al., 2025).

O estado do Rio Grande do Sul, localizado no sul do Brasil, apresenta regiões com condições propícias para o aproveitamento da energia eólica, especialmente em municípios como Cachoeira do Sul, onde estudos demonstraram velocidades médias de vento superiores a 6m/s e boa densidade de potência, caracterizando a região como tecnicamente viável para exploração eólica (NASCIMENTO et al., 2018). Esse cenário torna o estado um polo emergente em estudos e investimentos no setor.

Diante disso, este trabalho tem como objetivo principal desenvolver previsões da velocidade do vento, com enfoque sazonal e intervalar, aplicadas a três parques eólicos do Rio Grande do Sul. Para isso, são empregados modelos clássicos e modernos de séries temporais, como rede neural recorrente (do inglês, *Recurrent Neural Networks*, RNN), de Memória de Longo Prazo (do inglês, *Long Short-Term Memory*, LSTM) e TimeGPT. A abordagem intervalar permite não apenas estimar valores centrais, mas também quantificar a incerteza associada às previsões, contribuindo para uma tomada de decisão mais robusta (WANG; LI, 2023).

Uma das principais contribuições deste trabalho é a quantificação da incerteza nas previsões de velocidade do vento no Rio Grande do Sul, utilizando técnicas avançadas de aprendizado de máquina e métodos estatísticos, permitindo intervalos de previsão bem calibrados que fornecem informações sobre a confiabilidade e o risco associado às previsões. Além disso, o estudo contribui para a avaliação comparativa de diferentes

técnicas, como LSTM com previsão conformal, regressão quantílica e TimeGPT, oferecendo subsídios para a escolha de métodos mais robustos e precisos, tanto para previsão pontual quanto intervalar, e fornecendo ferramentas práticas para otimização da operação e planejamento de parques eólicos na região.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados, a Seção 3 descreve o conjunto de dados utilizados. A Seção 4 aborda a fundamentação teórica da metodologia, a Seção 5 descreve a metodologia aplicada, a Seção 6 discute os resultados. Por fim, a Seção 7 conclui o estudo e aborda as limitações e propostas para futuras pesquisas.

2. Trabalhos Relacionados

A evolução das abordagens voltadas à previsão da velocidade do vento tem se mostrado fundamental para otimizar o planejamento e a operação de sistemas eólicos, sobretudo no Sul do Brasil, onde há forte potencial de expansão da matriz renovável (ROCHA et al., 2023). No Rio Grande do Sul, marcado por variabilidade sazonal e regime de ventos expressivo, estudos recentes combinam modelos estatísticos, híbridos e de Inteligência Artificial (do inglês, Artificial Intelligence Ai) para elevar a acurácia e reduzir incertezas.

Nesse cenário, análises comparativas e aplicações recentes desenvolvidas em contextos internacionais oferecem subsídios importantes para a seleção e o aprimoramento de modelos preditivos. A seguir, são apresentados estudos que ilustram diferentes estratégias e seus resultados no enfrentamento dos desafios associados à previsão da velocidade do vento.

Xinyu Bai et al (2024) compararam modelos de Média Móvel Integrada Autorregressiva (do inglês, Autoregressive Integrated Moving Average, ARIMA), Rede Neural de Retropropagação (do inglês, Backpropagation Neural Network, BPNN) e o LSTM para prever velocidades do vento usando dados de uma estação meteorológica na China. O ARIMA destacou-se nas primeiras horas por sua capacidade de capturar tendências estáveis, enquanto a LSTM foi mais eficaz em cenários com maior variabilidade e para previsões de médio a longo prazo. O BPNN tentou modelar padrões complexos, mas apresentou tendência a superestimar os valores. Os resultados mostraram que a escolha do modelo deve considerar as características específicas da série de vento, como estabilidade e flutuações. Além de sugerir que a combinação de modelos aumente a robustez das previsões, sendo importante analisar o perfil dos dados para escolher a melhor abordagem, especialmente em micro-redes inteligentes.

Além dessas comparações entre abordagens tradicionais e modelos de aprendizado profundo, outras pesquisas têm se concentrado na incorporação de métodos probabilísticos para lidar com a variabilidade inerente aos dados meteorológicos em escala regional.

Para tratar explicitamente a incerteza, abordagens probabilísticas vêm ganhando espaço. Zhu et al. (2022) propuseram conjunto de abordagens (do inglês, *framework*), com redes neurais convolucionais LSTM + regressão quantílica (do inglês, *quantile regression*, QR) e correção de erro em tempo real, explorando dependências espaço-temporais em três regiões dos EUA; o método superou a avaliação em relação a outros modelos (do inglês *benchmarks*) e produziu intervalos mais confiáveis. De forma complementar, Hu et al. (2020) empregaram Rede Neural de Regressão Quantílica (do inglês, *Quantile Regression Neural Network*, QRNN) com otimização por Algoritmo de Otimização baseado em Gafanhotos (do inglês, *Grasshopper Optimization Algorithm*, GOA) para estimar quantis (p.ex., 0.5), gerando previsões intervalares robustas sem assumir distribuição paramétrica.

Seguindo a mesma linha de desenvolvimento de abordagens probabilísticas, Hu et al. (2020) aplicaram a técnica de QR como parte central de um modelo híbrido para previsão da velocidade do vento. O objetivo foi capturar não apenas previsões pontuais, mas também estimativas probabilísticas que representassem diferentes quartis (do inglês, *quantis*) da distribuição da série temporal. A abordagem permitiu modelar a variabilidade e a incerteza associadas à velocidade do vento. Para ampliar a flexibilidade do modelo, foi utilizada uma estrutura neural QRNN, que incorpora a QR em uma rede neural com função de perda assimétrica. A fim de evitar o problema de mínimos locais, os pesos e vieses da QRNN foram otimizados por meio do GOA. Os resultados mostraram que o quantil 0.5 apresentou o melhor desempenho preditivo, refletindo com maior fidelidade o comportamento central da série. Além disso, a modelagem quantílica mostrou-se eficaz na geração de previsões intervalares, destacando-se como uma ferramenta robusta para previsão probabilística em cenários de alta variabilidade, como os da energia eólica.

As previsões intervalares têm se consolidado como componente essencial em aplicações de energia eólica, especialmente onde a variabilidade dos ventos pode afetar a estabilidade do sistema elétrico. Diferentemente das previsões pontuais, que fornecem apenas uma estimativa central, as intervalares quantificam a incerteza das estimativas, permitindo estratégias mais seguras e adaptativas (LIU et al., 2022). No presente estudo, que modela a velocidade do vento no sul do Brasil, métodos capazes de fornecer intervalos de confiança são particularmente relevantes, dado que o regime de ventos da região é fortemente influenciado por fatores sazonais e climáticos complexos. Estratégias baseadas em QR e modelos híbridos capturam essa incerteza de forma mais realista, contribuindo para planos operacionais mais resilientes (LI et al., 2022).


Em síntese, os trabalhos analisados demonstram a diversidade de abordagens utilizadas para a previsão da velocidade do vento, desde modelos estatísticos tradicionais até técnicas baseadas em redes neurais profundas e algoritmos híbridos. Os resultados apontam que a escolha do modelo mais adequado depende fortemente das características da série temporal e do objetivo da aplicação – seja em micro-redes, sistemas de larga escala ou contextos regionais específicos. Além disso, a integração de abordagens determinísticas com estratégias probabilísticas, como a QR, tem se mostrado uma alternativa promissora para lidar com a complexidade e a incerteza dos dados meteorológicos, reforçando a importância de modelos flexíveis e adaptativos no apoio à transição energética.

3 Conjunto de Dados

Neste estudo utilizamos medições de velocidade do vento com resolução horária (m/s) fornecidas pelo INMET para Cambará do Sul (RS), cobrindo todo o ano de 2024 (INMET, 2025). A série apresentada na Figura 1 permite caracterizar variações intra-diárias e sazonais, além de sustentar testes de tendência e estacionariedade necessários à modelagem preditiva. Para uma análise mais detalhada, selecionou-se o mês de abril e maio, por representar uma transição entre regimes climáticos no sul do Brasil.

A seleção de Cambará do Sul apoia-se em evidências da literatura: a distribuição de Weibull oferece estimativas robustas do potencial eólico no RS (NASCIMENTO et al., 2021); há complementaridade entre fontes hídrica, solar e eólica no estado (BAGATINI et al., 2017); e o Atlas Eólico identifica zonas de alto potencial com medições em 80–120m (FEE, 2015). De acordo com o Balanço Energético do Estado do Rio Grande do Sul (SEPLAG, 2021); registra ~7,2 GW de capacidade instalada em 2021, com cerca de 20% de origem eólica, reforçando a pertinência de estudos locais de previsão e integração da geração (SEPLAG, 2021).

Diante desse contexto, a decomposição retratada na Figura 2 possibilita compreender de forma clara as dinâmicas de tendência, sazonalidade e ruído associadas à série. Primeiro, a tendência apresenta elevação gradual ao longo de abril, com picos mais pronunciados no fim do mês, indicando aumento persistente do nível médio da série. Segundo, a sazonalidade exibe um ciclo regular de periodicidade curta (intra-diária), com padrões repetidos quase idênticos, compatíveis com variações diárias típicas de velocidade do vento. Por fim, os resíduos oscilam em torno de zero, sem estrutura aparente ou autocorrelação visível e com dispersão aproximadamente constante, sugerindo que tendência e sazonalidade capturam a maior parte da dinâmica, restando sobretudo ruído aleatório de baixa intensidade.




Fonte: O Autor (2025).

Foram analisadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) para apoiar a especificação do modelo. A ACF sintetiza a associação seriada em múltiplas defasagens, enquanto a PACF isola a contribuição direta de uma defasagem específica (YAKUBU; SAPUTRA, 2022). Em Cambará do Sul, os gráficos mostram sinal estatístico até a 5ª defasagem, mas a PACF destaca essencialmente apenas a 1ª. Assim, fixou-se $p = 2$ como compromisso pragmático, preservando simplicidade e capturando dependências de curto alcance (Figuras 3 e 4 – ACF e PACF).

O teste de Dickey–Fuller aumentado (ADF) avaliou a estacionariedade da série temporal (HYNDMAN; ATHANASOPOULOS, 2018). A hipótese nula do ADF indica a presença de raiz unitária (não estacionariedade), enquanto sua rejeição sugere estacionariedade. Para reduzir componentes não estacionários, aplicou-se diferenciação de primeira ordem à série, conforme demonstrado na Tabela 1 dos resultados dos testes KPSS, ADF, Mann–Kendall e Kruskal–Wallis para Cambará do Sul.


Na série original de Cambará do Sul, o teste KPSS indicava ausência de estacionariedade, enquanto o ADF apontava estacionariedade, resultado esperado dado que possuem hipóteses nulas opostas. O teste Mann–Kendall não mostrou tendência significativa, mas o Kruskal–Wallis identificou sazonalidade. Após a diferenciação, KPSS e ADF convergiram, confirmando estacionariedade. Nesse estágio, não houve tendência nem sazonalidade, validando o pré-processamento aplicado. Garantir estacionariedade é fundamental para modelos robustos, pois componentes não estacionários aumentam incertezas e reduzem a capacidade preditiva (HYNDMAN; ATHANASOPOULOS, 2018).

Figura 2 – Decomposição da Série Temporal - Cambará do Sul (Abril).




Fonte: O Autor (2025).

Figura 3 – Gráfico do ACF



Fonte: O Autor (2025).

Figura 4– Gráfico do PACF



Fonte: O Autor (2025).

Tabela 1 – Pesquisa qualitativa versus pesquisa quantitativa

Teste	Diferenciação	Estatística	Valor Crítico	Conclusão
KPSS	Não	0.1826	0.146	Não há estacionariedade
ADF	Não	-7.8353	0.05	Há estacionariedade
Mann-Kendall	Não	0.0064	0.05	Não há tendência
Kruskal-Wallis	Não	256.213	0.05	Há sazonalidade
KPSS	Sim	0.0211	0.0146	Há estacionariedade
ADF	Sim	-10.779	0.05	Há estacionariedade
Mann-Kendall	Sim	-0.8009	0.05	Não há tendência
Kruskal-Wallis	Sim	5.1824	0.05	Não há sazonalidade

Fonte: O Autor (2025)

4. Fundamentação Teórica

Nesta seção serão apresentados aspectos teóricos característicos dos métodos de previsão empregados na metodologia deste estudo.

4.1 Métodos de Previsão

O LSTM é uma arquitetura de RNN projetada para superar as limitações das RNNs convencionais na modelagem de dependências de longo prazo em dados sequenciais.

Esse modelo introduz o conceito de células de memória e mecanismos de controle denominados portas (de entrada, esquecimento e saída), que regulam de forma dinâmica o fluxo de informações ao longo da sequência temporal. Essa estrutura permite que o LSTM armazene informações relevantes por longos períodos e descarte padrões irrelevantes de maneira seletiva (KRICHEN; MIHOUB, 2025). Essas características tornam o LSTM particularmente eficaz em tarefas que exigem sensibilidade ao contexto histórico e à ordem temporal dos dados, como previsão de séries temporais, reconhecimento de fala e tradução automática (HOCHREITER, 1997). No entanto, seu desempenho está diretamente condicionado à quantidade de dados disponíveis, ao ajuste fino dos hiperparâmetros e à complexidade computacional envolvida no processo de treinamento, especialmente em contextos multivariados ou de alta frequência.

O TimeGPT é um modelo pré-treinado baseado em transformadores, pré-treinado em larga escala, capaz de capturar padrões complexos em séries temporais com alta flexibilidade e generalização. Diferencia-se pela exposição a dados multissetoriais (energia, finanças, saúde e IoT) durante o pré-treinamento, o que possibilita previsões em novos domínios sem re-treinamento — característica da previsão sem treinamento prévio (do inglês, *zero-shot forecasting*)(LIAO et al., 2025). Neste trabalho, o TimeGPT foi aplicado diretamente às séries de velocidade do vento da localidade analisada, utilizando apenas os dados históricos disponíveis, sem um ajuste fino (do inglês, *fine-tuning*). Assim, aproveita-se o conhecimento adquirido em ampla variedade de séries temporais multissetoriais, incluindo energia, finanças e meteorologia (LIAO et al., 2025). Além de capturar padrões temporais complexos, o TimeGPT estima a incerteza das previsões, favorecendo análises probabilísticas mais robustas, garantindo escalabilidade e desempenho consistente mesmo em cenários de alta variabilidade (LIAO et al., 2025).

4.2 Previsão Probabilística

A previsão probabilística busca representar não apenas o valor esperado de uma variável futura, mas também a incerteza associada às previsões. Em vez de fornecer uma estimativa pontual única, gera distribuições ou intervalos de predição que descrevem a variabilidade potencial dos resultados. Essa abordagem é essencial em contextos de risco elevado ou sujeitos a eventos extremos, nos quais não basta saber a previsão central: é igualmente necessário compreender a amplitude de valores possíveis e sua probabilidade de ocorrência. Segundo Pasche, Lam e Engelke (2025), a previsão probabilística oferece instrumentos mais robustos para avaliação de risco, permitindo ao tomador de decisão considerar diferentes cenários e graus de confiança de forma explícita.

Existem diferentes formas de construir intervalos de previsão. Métodos como o bootstrap de resíduos permitem reamostrar erros e capturar a incerteza sem pressupor distribuições específicas; já a assunção gaussiana utiliza a hipótese de normalidade para gerar intervalos simétricos em torno da previsão, embora seja sensível a assimetrias e heterocedasticidade. A regressão quantílica estima diretamente quantis da distribuição condicional, permitindo representar caudas pesadas e distribuições assimétricas (PASCHE; LAM; ENGELKE, 2025).

4.3 Medidas de Desempenho

Essas medidas são essenciais para quantificar a qualidade, precisão e eficácia de um modelo de previsão, especialmente no contexto de séries temporais. Elas permitem comparar diferentes métodos e identificar qual apresenta resultados mais próximos dos valores reais observados (HYNDMAN; ATHANASOPOULOS, 2018). A Tabela 2 apresenta as fórmulas de todas as medidas de performance apresentadas abaixo.

Tabela 2 – Pesquisa qualitativa versus pesquisa quantitativa

Teste	Equação	Definição da Fórmula
MAE	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	Calcula a média das diferenças absolutas entre os valores reais y_i e previstos $\hat{y}_i$ (REICH et al., 2016).
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Raiz quadrada da média dos quadrados dos erros, penaliza mais fortemente os grandes desvios (HODSON, 2022).
SMAPE	$\frac{100\%}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{(y_i + \hat{y}_i)/2}$	Varição do MAPE que usa a média dos valores absolutos reais e previstos no denominador. (HYNDMAN; KOEHLER, 2006).
PICP	$\frac{1}{n} \sum_{i=1}^n c_i, \quad c_i = \begin{cases} 1, & \text{se } y_i \in I_i \\ 0, & \text{caso contrário} \end{cases}$	Proporção dos valores reais y_i que estão dentro dos intervalos de previsão I_i (CRUZ; MARÍN; SÁEZ, 2018).
PINAW	$\frac{1}{nR} \sum_{i=1}^n (U_i - L_i)$	Largura média dos intervalos de previsão normalizada pela amplitude R da série. CRUZ; MARÍN; SÁEZ (2018).
ACE	$ PICP - \mu $	Erro absoluto entre o PICP obtido e o nível de confiança desejado μ (BOZORG et al., 2020).

Fonte: O Autor (2025)

Nota: R é a amplitude da série, μ é o nível de confiança desejado, e γ , n são constantes de penalização, y_i é o valor real, $\hat{y}_i$ é o valor previsto, L_i e U_i são os limites inferior e superior do intervalo de previsão.

5. Metodologia

O Anexo 1 representa um fluxograma com o resumo das etapas realizadas neste trabalho, desde a coleta e preparação dos dados até a modelagem preditiva e avaliação dos resultados. Nele estão descritas as principais fases do processo: análise exploratória e estatística, tratamento e validação das séries temporais, construção dos modelos (LSTM, LSTM com QR e TimeGPT), e posterior avaliação por meio de métricas de desempenho e comparação entre as localidades estudadas.

As amostras foram construídas por meio de janela deslizante (do inglês, *look-back*) e divididas sequencialmente em 80% para treino e 20% para teste, preservando a ordem temporal. Dentro do conjunto de treino, 20% foram reservados para calibração/validação, utilizados no ajuste do modelo e na geração de intervalos de previsão.

6. Resultados e Discussões

Nos resultados obtidos para Cambará do Sul, observou-se um desempenho moderado em termos de acurácia, porém com elevada estabilidade na cobertura e dispersão dos intervalos de previsão. Os valores de MAE variaram entre 0,714 e 0,835 entre os métodos avaliados, enquanto o PICP oscilou de 0,895 a 0,960, indicando consistência na confiabilidade dos intervalos gerados.

O método *Conformal Prediction* destacou-se por apresentar o melhor equilíbrio entre cobertura e largura dos intervalos (PICP = 0,960; PINAW = 0,476), demonstrando adequação à dinâmica menos volátil desta estação e favorecendo uma calibragem estatística mais precisa dos limites preditivos. Já o modelo TimeGPT, aplicado para

previsão de três passos à frente , apresentou o melhor desempenho dentro da sua categoria em Cambará do Sul, com MAE e RMSE de 0,835 – valores consideravelmente inferiores aos demais modelos dessa abordagem. Esses resultados sugerem que, em contextos de variabilidade moderada, abordagens baseadas em calibração empírica, como o *Conformal Prediction*, ou arquiteturas pré-treinadas bem ajustadas, como o TimeGPT, podem proporcionar um equilíbrio mais favorável entre precisão, cobertura e largura dos intervalos, especialmente em horizontes de previsão mais desafiadores.


Os resultados obtidos a partir das diferentes abordagens preditivas evidenciam o impacto da escolha do método na qualidade da previsão intervalar da velocidade do vento. A Tabela 3 sintetiza as métricas quantitativas para cada modelo e método de intervalo, apresentando um resumo do desempenhos dos modelos para um passo à frente (h-1) e três passos à frente (h-3), conforme apropriado para cada abordagem. As Figuras 5 à 9 ilustram visualmente o comportamento das previsões e dos intervalos de confiança para o período de 15/05/2024 a 21/05/2024.

Tabela 3 – Resultados por método aplicado

Método	PICP	PINAW	MAE	RMSE	SMAPE	ACE
bootstrap (h-1)	0.895	0.382	0.764	1.002	30.750	0.054
gaussiano (h-1)	0.937	0.435	0.747	1.006	25.713	-0.012
conformal (h-1)	0.960	0.476	0.747	1.006	25.713	0.010
quantile (h-1)	0.921	0.405	0.714	0.959	24.622	-0.028
timegpt (h-3)	0.927	0.822	0.835	0.835	48.899	-0.022


Fonte: O Autor (2025)

Figura 5 – Previsão com Bootstrap




Fonte: O Autor (2024)

Figura 6 – Previsão com Gaussiano




Fonte: O Autor (2024)

Figura 7 – Previsão com Conformal




Fonte: O Autor (2025)

Figura 8– Previsão com Quantile Regression



Fonte: O Autor (2025)

Figura 9 – Previsão da velocidade média do vento utilizando TimeGPT.



Fonte: O Autor (2025).

7. Conclusão

Este trabalho avaliou a previsão intervalar da velocidade do vento em Cambará do Sul (RS), comparando métodos tradicionais (bootstrap, distribuição gaussiana) e avançados (Conformal Prediction, Regressão Quantílica e TimeGPT) aplicados à geração eólica. O objetivo foi identificar abordagens mais eficazes para produzir previsões intervalares precisas e confiáveis, considerando o regime de ventos da região.

Os resultados mostraram que a Regressão Quantílica apresentou o menor erro absoluto médio ($MAE = 0,714$), enquanto o Conformal Prediction obteve a melhor calibragem dos intervalos ($PICP = 0,960$; $PINAW = 0,476$). Mesmo em horizontes mais longos, o TimeGPT manteve desempenho competitivo ($MAE = 0,835$; $PICP = 0,927$), destacando-se pela robustez. Esses achados indicam que métodos baseados em calibração empírica são mais eficazes para séries estáveis, enquanto modelos pré-treinados se mostram adequados para horizontes de previsão ampliados.

Como limitação, destaca-se que este estudo utilizou apenas dados meteorológicos e não integrou dados operacionais de parques eólicos reais, o que pode restringir a avaliação prática do desempenho dos modelos em condições operacionais. Para trabalhos futuros, convém incluir dados reais de produção e operação diretamente dos parques eólicos, testar modelos híbridos e ampliar a base de dados para aumentar a precisão, a robustez e a aplicabilidade prática das previsões intervalares.

Referências

- BAGATINI, M. L. et al. Complementaridade entre fontes renováveis de energia no estado do Rio Grande do Sul. *Revista Brasileira de Energia Renovável*, v. 6, n. 2, p. 364-383, 2017.
- BOZORG, M. et al. Bayesian bootstrap quantile regression for probabilistic photovoltaic power forecasting. *Protection and Control of Modern Power Systems*, v. 5, n. 21, 2020.
- CLIFTON, A. et al. Research challenges and needs for the deployment of wind energy in hilly and mountainous regions. *Wind Energy Science*, 2022. DOI: 10.5194/wes-7-2231-2022.
- CRUZ, N.; MARÍN, L. G.; SÁEZ, D. Neural network prediction interval based on joint supervision. In: *INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN)*, 2018. Anais [...]. IEEE, 2018. p. 1–8.

FEE – FUNDAÇÃO DE ECONOMIA E ESTATÍSTICA. Atlas Eólico do Rio Grande do Sul. Porto Alegre, 2015. Disponível em: <https://energia.rs.gov.br/atlas-eolico-do-rio-grande-do-sul>. Acesso em: 23 jun. 2025.

HODSON, T. O. Root-mean-square error (rmse) or mean absolute error (mae): when to use them or not. *Geoscientific Model Development*, v. 15, n. 14, p. 5481–5487, 2022. DOI: 10.5194/gmd-15-5481-2022.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, n. 4, p. 679–688, 2006.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2. ed. OTexts, 2018. p. 68-69. Disponível em: <https://otexts.com/fpp2>. Acesso em: 23 jun. 2025.

INMET – INSTITUTO NACIONAL DE METEOROLOGIA. Banco de Dados Meteorológicos para Ensino e Pesquisa. 2025. Disponível em: <https://bdmep.inmet.gov.br/>. Acesso em: 27 jul. 2025.

KRICHEN, M.; MIHOUB, A. Long Short-Term Memory Networks: A Comprehensive Survey. *AI*, v. 6, n. 9, p. 215, 2025. DOI: <https://doi.org/10.3390/ai6090215>.

LIAO, W. et al. TimeGPT in load forecasting: A large time series model perspective. *Applied Energy*, v. 379, p. 124793, 2025. DOI: 10.1016/j.apenergy.2024.124973.

LI, Z. et al. Wind power probabilistic forecasting based on combined decomposition and deep learning quantile regression. *Frontiers in Energy Research*, v. 10, 2022. DOI: <https://doi.org/10.3389/fenrg.2022.937240>.

LIU, G. et al. A Novel Hybrid Machine Learning Model for Wind Speed Probabilistic Forecasting. *Energies*, v. 15, n. 19, p. 6942, 2022. DOI: <https://doi.org/10.3390/en15196942>.

LOZA, B. et al; MINCHALA, L. I.; OCHOA-CORREA, D.; MARTINEZ, S. Grid-friendly integration of wind energy: A review of power forecasting and frequency control techniques. *Sustainability*, v. 16, n. 21, p. 9535, 2024. DOI: <https://doi.org/10.3390/su16219535>.

MARUTHI, M. et al. Multi-model integration for dynamic forecasting (MIDF): a framework for wind speed and direction prediction. *Artificial Intelligence Review*, Springer, 2025. DOI: 10.1007/s10462-025-11140-x.

MCKENNA, Russell et al. System impacts of wind energy developments: Key research challenges and opportunities. *Joule*, 2024. DOI: <https://doi.org/10.1016/j.joule.2024.11.016>

MSIGWA, Goodluck; IGHALO, Joshua O.; YAP, Pow-Seng. Considerations on environmental, economic, and energy impacts of wind energy generation: Projections towards sustainability initiatives. *Science of The Total Environment*, 2022. DOI: <http://dx.doi.org/10.1016/j.scitotenv.2022.157755>.

NASCIMENTO, A. et al. Evaluation of wind potential in a region of southern Brazil. *Ciência e Natura*, 2018. DOI: 10.5902/2179460X30711.

NASCIMENTO, C. A. M. et al. Análise estatística da velocidade do vento com aplicação da distribuição de Weibull em Cachoeira do Sul - RS. *Revista Brasileira de Meteorologia*, v. 36, n. 3, p. 471-481, 2021. Disponível em: <https://rbmet.org.br>. Acesso em: 23 jun. 2025.

PASCHE, O. C.; LAM, H.; ENGELKE, S. Extreme Conformal Prediction: Reliable Intervals for High-Impact Events. *arXiv preprint*, arXiv:2505.08578, 2025.

ROCHA, Paulo Alexandre Costa *et al.* Trends on Wind Speed Forecasting: Umbrella Review of the Last 5 Years. *Preprints*, 2023. DOI: 10.20944/preprints202308.1578.v1.

REICH, N. G. et al. Case study in evaluating time series prediction models using the relative mean absolute error. *American Statistician*, v. 70, n. 3, p. 285–292, 2016. DOI: 10.1080/00031305.2016.1148631.

SEPLAG – SECRETARIA DE PLANEJAMENTO, GOVERNANÇA E GESTÃO. Balanço Energético do Estado do Rio Grande do Sul – 2021. Porto Alegre, 2021. Disponível em: <https://planejamento.rs.gov.br/balanco-energetico>. Acesso em: 23 jun. 2025.

WANG, J.; LI, Z. Wind speed interval prediction based on multidimensional time series of Convolutional Neural Networks. *Engineering Applications of Artificial Intelligence*, v. 121, p. 105987, 2023. DOI: <https://doi.org/10.1016/j.engappai.2023.105987>.


XINYU, B. et al. Data-driven Prediction Model Selection Considering Time Series Characteristics of Wind Speed. In: *IEEE CONFERENCE PROCEEDINGS*, 2024. IEEE. DOI: 10.1109/ICETCI61221.2024.10594485.

YAKUBU, U. A. AND SAPUTRA, M. P. A. Time series model analysis using autocorrelation function (acf) and partial autocorrelation function (pacf) for e-wallet transactions during a pandemic. *International Journal of Global Operations Research*, 2022, v.3, n.2, p.83.

ZHU, S. et al. Enhanced probabilistic spatiotemporal wind speed forecasting based on deep learning, quantile regression, and error correction. *Journal of Energy Engineering*, v. 148, n. 2, p. 04022004, 2022. DOI: 10.1061/(ASCE)EY.1943-7897.0000823.

ANEXO

Anexo 1 – Metodologia do processo aplicado para previsão de séries temporais.



Fonte: O Autor (2025).