

Análise Comparativa de Técnicas de Aprendizado de Máquina na Previsão da Geração de Energia Eólica: Um Estudo de Caso de Dados do Brasil

Bruna Rupp Ruela

Instituto Federal do Espírito Santo
Av. dos Sabiás, 330 - Morada de Laranjeiras, Serra - ES, 29166-630
brunarupp@gmail.com

Jordana Correia Aguiar

Instituto Federal do Espírito Santo
Av. dos Sabiás, 330 - Morada de Laranjeiras, Serra - ES, 29166-630
jordanacorreiaaguiar@gmail.com

Sérgio Nery Simões

Instituto Federal do Espírito Santo
Av. dos Sabiás, 330 - Morada de Laranjeiras, Serra - ES, 29166-630
sergio@ifes.edu.br

Danilo de Paula e Silva

Instituto Federal do Espírito Santo
Av. dos Sabiás, 330 - Morada de Laranjeiras, Serra - ES, 29166-630
danilo.silva@ifes.edu.br

RESUMO

A energia eólica é estratégica na transição energética, mas sua intermitência dificulta a previsão da geração. Este estudo propõe modelos de aprendizado de máquina para previsão de potência eólica em horizontes de 1 a 6 horas, utilizando dados reais de turbinas localizadas no Espírito Santo (jan/2023 a fev/2025) e no Rio Grande do Sul (fev/2020 a jan/2021). Foram comparados algoritmos ensemble (Random Forest, Gradient Boosting, XGBoost, LightGBM) e redes neurais profundas (MLP, LSTM, GRU, TCN, Transformer), com entradas baseadas em variáveis meteorológicas e defasagens temporais. A validação cruzada temporal foi aplicada para preservar a ordem cronológica dos dados, com avaliação por métricas estatísticas (RMSE, MAE e R^2). No RS, o TCN reduziu o erro em até 3,6% em relação ao segundo melhor modelo. O LightGBM foi o mais eficiente, com tempo de inferência até 99 vezes menor que o TCN. A análise SHAP destacou o vento como o principal preditor.

PALAVRAS CHAVE. Energia Eólica, Previsão de potência, Aprendizado de Máquina, SHAP, Validação Cruzada Temporal.

ABSTRACT

Wind energy is strategic in the energy transition, but its intermittency makes generation forecasting challenging. This study proposes machine learning models for wind power forecasting

over short-term horizons (1 to 6 hours), using real data from turbines located in Espírito Santo (Jan/2023 to Feb/2025) and Rio Grande do Sul (Feb/2020 to Jan/2021). Ensemble algorithms (Random Forest, Gradient Boosting, XGBoost, LightGBM) and deep neural networks (MLP, LSTM, GRU, TCN, Transformer) were compared, with input features based on meteorological variables and temporal lags. Temporal cross-validation was applied to preserve the chronological order of the data, and models were evaluated using statistical metrics (RMSE, MAE, and R^2). In the RS case, the TCN model reduced error by up to 3.6% compared to the second-best model. LightGBM combined competitive accuracy with the highest inference speed, running up to 99 times faster than TCN. SHAP analysis identified wind speed as the most important predictive variable.

KEYWORDS. *Wind Energy, Power forecasting, Machine Learning, SHAP, Temporal Cross Validation.*

1. Introdução

A crescente demanda por segurança energética e a intensificação das mudanças climáticas têm impulsionado a transição para fontes de energia renovável. Dentre essas, a energia eólica destaca-se por sua disponibilidade abundante, baixos custos operacionais e contribuição significativa à descarbonização das matrizes energéticas [Jacobson e Delucchi, 2011]. A capacidade eólica instalada global cresce a uma taxa média de 9% ao ano [Council, 2023], evitando emissões expressivas de CO_2 . No Brasil, a energia eólica evitou a emissão de 34,4 milhões de toneladas de CO_2 em 2022, consolidando-se como a segunda maior fonte da matriz elétrica nacional [Associação Brasileira de Energia Eólica, 2023].

Apesar de seu potencial, a geração eólica é altamente dependente de variáveis meteorológicas e geográficas, como intensidade e direção dos ventos, temperatura, pressão e relevo [Manwell et al., 2010]. Essa variabilidade introduz incertezas operacionais, exigindo sistemas de previsão confiáveis para garantir a estabilidade da rede e otimizar a operação do sistema elétrico. O avanço de tecnologias de medição e a maior disponibilidade de dados históricos de turbinas têm possibilitado o uso de abordagens mais robustas, como algoritmos de aprendizado de máquina e aprendizado profundo, no contexto da previsão eólica de curto prazo [Zhao et al., 2021].

Embora estudos internacionais demonstrem avanços significativos na previsão de energia eólica [Zhang e Liu 2022; Liu et al. 2025], no contexto brasileiro as aplicações ainda são limitadas por fatores como disponibilidade de dados e heterogeneidade climática, reforçando a necessidade de investigações aplicadas com dados locais. Este trabalho realiza uma análise comparativa de diferentes algoritmos supervisionados aplicados à previsão de potência eólica para horizontes de 1h a 6h para previsão de energia de duas turbinas localizadas em regiões distintas do Brasil — Espírito Santo (ES) e Rio Grande do Sul (RS) — visando avaliar a robustez dos modelos diante de diferentes padrões de variabilidade eólica, aumentando a generalização dos resultados. Os modelos avaliados incluem métodos ensemble (Random Forest, Gradient Boosting, XGBoost, LightGBM), redes neurais (MLP, LSTM, GRU, TCN e Transformer), sendo todos treinados com defasagens temporais como entrada. A avaliação é conduzida por meio de validação cruzada temporal e análise de interpretabilidade via SHAP [Lundberg e Lee, 2017], além de considerar o custo computacional de inferência para aplicação prática em ambientes operacionais [Li et al., 2023].

2. Métodos

2.1. Organização proposta

Esta subseção descreve a metodologia utilizada para comparar abordagens de aprendizado de máquina para previsão da geração de energia eólica para os dois locais analisados. A estrutura consiste em várias etapas: coleta de dados, geração de potencia através de modelo matemático [e Silva et al., 2021], pré-processamento, implementação do modelo e avaliação de desempenho.

O objetivo é determinar os melhores métodos para prever com precisão a energia eólica de uma turbina em uma escola federal. A Figura 1 descreve estrutura para avaliar e comparar os modelos de aprendizado de máquina. Essa abordagem metodológica é detalhada abaixo:




Figura 1: Diagrama geral da experimentação.

- **Turbinas Eólicas:** As turbinas eólicas modelo GERAR 246 fornecidas pela empresa brasileira Enersud [Enersud, 2024]. Ambas geram informações diárias, semanais e mensais sendo possível extrair dados no formato MS-Excel via software próprio.
- **Dados meteorológicos:** Os dados meteorológicos [Guaitolini et al., 2023] foram obtidos por meio de estações meteorológica automática (EMA) instaladas nas dependências da escola pública federal na Serra ES e no município de Santa Vitória do Palmar no RS, localizadas nas coordenadas geográficas aproximadas de 20°14'29.9"S, 40°17'38.5"W, 40°17'38.5"W e 33°32'30.84"S, 53°23'47.88"W, respectivamente.
- **Modelo Analítico:** modelo matemático de conversão de dados meteorológicos em potência renovável proposto por [e Silva et al., 2020]. Utiliza o framework Mixed Logical Dynamical (MLD) para transformar previsões meteorológicas (vento, irradiância) em previsões de geração eólica e solar — essas previsões são então usadas em modelos de otimização.
- **Coleta e Processamento de Dados:** Os dados meteorológicos e a saída potência gerada (W) foram consolidados em um *dataset* no formato excel, em seguida tratados com remoção de

valores ausentes, filtros de velocidade do vento e engenharia de *features* com criação de novas variáveis como *datetime*, *lags* temporais, mês, ano.

- **Validação Cruzada em Séries Temporais:** Avaliação de diversos modelos de Machine Learning para previsão de energia eólica, incluindo redes neurais, modelos ensemble (Random Forest, XGBoost) e Deep Learning (GRU, LSTM, TCN), além de ajuste de hiperparâmetros.
- **Teste de Wilcoxon signed-rank:** Aplicado para comparar estatisticamente os erros de previsão entre modelos, identificando diferenças significativas de desempenho de forma robusta e não paramétrica.
- **Interpretação com SHAP:** Utilizado para analisar importância, dependência e interações entre variáveis, proporcionando maior transparência e interpretabilidade dos modelos preditivos.

2.2. Processamento dos dados e análises

Esta seção descreve a preparação e análise exploratória dos dados utilizados na previsão de geração eólica nas turbinas localizadas no Espírito Santo (ES) e Rio Grande do Sul (RS), com taxa de amostragem de 15 minutos (ES) e 1 hora (RS) respectivamente. Os dados, tratados separadamente, incluem variáveis meteorológicas como temperatura, umidade, pressão, vento e precipitação, sendo a potência gerada a variável alvo. Foram removidas observações incompletas e registros com vento abaixo de 3.6 m/s, limite mínimo para geração das turbinas GERAR 246.

Com o objetivo de transformar as séries temporais em um problema de aprendizado supervisionado, foram aplicadas defasagens temporais (*lags*) de 1h, 2h e 3h, respeitando a granularidade de cada turbina. Essa abordagem resulta em vetores de entrada que representam as condições meteorológicas passadas, com previsão da potência gerada em horizontes futuros de 1 a 6 horas. A Tabela 1 resume as estatísticas descritivas das variáveis de entrada e saída após o processamento para cada localidade.

A Figura 2 mostra a série temporal da potência gerada, a turbina do RS apresenta uma potência média superior, mas com maior variabilidade, refletida em maiores desvios padrão. Por outro lado, a turbina ES, apesar de gerar em menor escala e sofrer momentos de interrupção devido longas a falhas do equipamento, demonstra maior estabilidade nos dados no período de geração, o que impacta diretamente nas estratégias de modelagem.

Tabela 1: Estatísticas descritivas das turbinas ES e RS após o pré-processamento.

Turbina	Coleta	Nº amostras	Vento médio (m/s)	Potência média (W)	Desvio padrão potência	Potência máxima (W)	Potência mínima (W)
ES	15 min	18632	6,23	103,10	38,20	198,40	0,00
RS	1 h	5432	7,85	243,20	91,50	351,70	0,00

2.3. Algoritmos de Machine Learning

Esta subseção descreve os algoritmos de aprendizado de máquina empregados para previsão da geração de energia eólica nas duas regiões estudadas. Os modelos são organizados em duas categorias principais: métodos de *ensemble* e redes neurais profundas. Cada classe cumpre um papel específico na modelagem das características temporais, não lineares e ruidosas dos dados meteorológicos associados à geração de energia eólica. A Tabela 2 resume a classificação dos algoritmos utilizados no estudo, bem como suas abreviações e descrições gerais. O conjunto de modelos contempla desde métodos clássicos baseados em árvores até arquiteturas neurais sequenciais e convolucionais, com diferentes capacidades de captura de padrões temporais e não lineares.




Figura 2: Séries temporais da potência gerada por local.

Tabela 2: Categorias e algoritmos de aprendizado de máquina utilizados no estudo.

Categoria	Algoritmos Utilizados
Ensemble	Random Forest (RF), Gradient Boosting (GB), XGBoost (XGB), LightGBM (LGBM)
Aprendizado Profundo	MLP, LSTM, GRU, Temporal CNN (TCN), Transformer

2.3.1. Métodos *Ensemble*

- **Random Forest (RF):** Combina várias árvores de decisão treinadas com subconjuntos diferentes do conjunto de dados. É eficaz na redução de *overfitting* e lida bem com dados meteorológicos ruidosos e variáveis [Liu et al., 2025].
- **Gradient Boosting (GB):** Constrói modelos sequencialmente, cada um corrigindo os erros do anterior. Ideal para relações não lineares complexas, comuns em séries temporais de vento [Kim e Park, 2023].
- **XGBoost (XGB):** Variante otimizada do Gradient Boosting, altamente eficiente e com regularização embutida para evitar sobreajuste. Apresenta bom desempenho mesmo com dados esparsos [Zheng e Wu, 2019].
- **LightGBM (LGBM):** Variante de boosting com divisão de histogramas e crescimento de árvore orientado a folhas, garantindo maior velocidade e eficiência em grandes volumes de dados [Li e Zhang, 2022].

2.3.2. Redes Neurais Profundas

- **MLP (Multilayer Perceptron):** Arquitetura feedforward com camadas densas, útil para aprender relações não lineares em dados meteorológicos tabulares [Reddy e Kumar, 2024].

- **LSTM (Long Short-Term Memory):** RNN especializada em capturar dependências de longo prazo em séries temporais. Suporta aprendizado sequencial com memória de longo prazo [Wang e Zhao, 2023].
- **GRU (Gated Recurrent Unit):** Variante mais leve que a LSTM, com desempenho similar e arquitetura simplificada. Ideal para prever padrões temporais com custo computacional reduzido [Liu e Zhang, 2023].
- **TCN (Temporal Convolutional Network):** Rede convolucional adaptada para séries temporais. Captura dependências locais e padrões sazonais com maior paralelismo computacional que RNNs [Zhang e Liu, 2022].
- **Transformer:** Arquitetura baseada em atenção, originalmente proposta para NLP, mas recentemente aplicada em previsão de séries temporais. Capaz de modelar dependências de longo alcance com eficiência [Li e Zhao, 2023].

2.4. Avaliação dos modelos de *Machine Learning*

Esta seção descreve os critérios, procedimentos e métricas utilizados para avaliar o desempenho dos algoritmos de aprendizado de máquina empregados na previsão de potência eólica. A abordagem adotada envolve validação cruzada temporal e análise estatística dos erros de previsão, com o objetivo de garantir a robustez e a aplicabilidade dos modelos em contextos reais de geração de energia. A avaliação considera diferentes horizontes de previsão (1 a 6 horas) e é realizada separadamente para cada turbina (ES e RS), respeitando a cronologia dos dados.

2.4.1. Métricas de Desempenho

Para avaliar os modelos, três métricas foram utilizadas: Erro Absoluto Médio (MAE), a Raiz Quadrada do Erro Quadrático Médio (RMSE) e R2 (coeficiente de determinação), dadas, respectivamente, por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

onde consideramos y_i como os valores reais, $\hat{y}_i$ como os valores preditos e n como o número total de observações.

A validação foi conduzida por meio da estratégia de validação cruzada para séries temporais, dividindo-se os dados em 5 *folds* sequenciais sem embaralhamento, respeitando a ordem temporal [Bergmeir e Benítez, 2018; Bontempi et al., 2012]. Esse método assegura que os modelos sejam avaliados em cenários realistas, nos quais as previsões são feitas com base em dados históricos, replicando o fluxo operacional real das usinas eólicas. Além de aumentar a confiabilidade das avaliações, essa abordagem também permitiu estimar a variabilidade *inter-fold* dos modelos e reduzir riscos de *overfitting* [Cerqueira et al., 2020].

Para interpretar o impacto das variáveis meteorológicas nas previsões dos modelos baseados em árvore, utilizou-se a abordagem SHAP (SHapley Additive exPlanations) [Lundberg e Lee, 2017]. Essa técnica permitiu avaliar a contribuição individual de cada *feature* para a previsão de

potência, identificando, por exemplo, a velocidade do vento como principal preditor, seguida pela direção do vento e pressão atmosférica. Foram gerados gráficos de importância, dependência e interações, revelando que, apesar da dominância da velocidade, outras variáveis como umidade e temperatura também possuem efeitos relevantes, especialmente em condições de baixa geração. A Figura 3 ilustra um exemplo de explicação SHAP para o horizonte de 1h aplicado às duas turbinas.




Figura 3: Importância média das variáveis segundo SHAP.

3. Resultados

Esta seção descreve os critérios usados para avaliar o desempenho dos modelos, incluindo métricas de erro, validação cruzada temporal e testes estatísticos como o teste Wilcoxon.

3.1. Validação Cruzada Temporal

Os dados foram particionados utilizando validação cruzada de séries temporais com 5 divisões sequenciais (*folds*). Além disso, os melhores modelos foram obtidos por meio de busca em grade (*grid search*), determinando os valores ideais de hiperparâmetros com base no desempenho nos conjuntos de treinamento e validação. Os experimentos revelaram diferenças sistemáticas no desempenho dos modelos de previsão de potência. Mesmo após ajuste de hiperparâmetros, observou-se que os modelos apresentaram maior precisão e estabilidade preditiva no cenário do Espírito Santo (ES).

Na turbina do Espírito Santo, os modelos baseados em árvore, especialmente Gradient Boosting e Random Forest, demonstraram os melhores desempenhos nos primeiros horizontes. Por exemplo, o Gradient Boosting alcançou um R^2 de 0.572, com MAE de 42.89 W e RMSE de 60.10 W no horizonte de 1h, como observado na Figura 4. Esses modelos também se mostraram robustos até o horizonte de 4h, antes de sofrerem degradação significativa de desempenho.

A Tabela 3 apresenta os resultados médios da validação cruzada com 5 *folds* no horizonte de 1 hora (para efeitos de demonstração) para os modelos testados na turbina do ES e do RS,




Figura 4: Avaliação das métricas MAE, RMSE e R^2 dos modelos nas regiões ES e RS.

expressos em termos de MAE, RMSE e seus respectivos desvios padrão. Observa-se que o modelo TCN apresentou o melhor desempenho em ambas as regiões, com os menores erros absolutos e quadráticos. No ES, obteve MAE de 42.71 ± 8.71 W e RMSE de 59.66 ± 12.88 W. No RS, ainda que com valores mais altos, também liderou com MAE de 131.76 ± 8.26 W e RMSE de 187.56 ± 13.16 W. Entre os métodos baseados em árvore (GB, RF e LightGBM), o desempenho foi robusto em ambos os cenários no horizonte de 1h, superando os modelos neurais em custo computacional e estabilidade. Já modelos como MLP, GRU e LSTM apresentaram desempenho aceitável no ES, mas perderam eficácia no RS, indicando sensibilidade à variabilidade temporal e complexidade local dos dados. Para horizontes superiores, no Espírito Santo, os modelos de árvore mantiveram bons resultados até 4h, com quedas graduais. O TCN permaneceu competitivo, e as redes neurais (LSTM, GRU) tiveram maior deterioração nas métricas. No Rio Grande do Sul, o TCN também liderou até 3h, enquanto modelos de árvore como LightGBM e Gradient Boosting mantiveram estabilidade. O MLP apresentou desempenho estável até 3h. As redes recorrentes (GRU e LSTM) não se adaptaram bem, apresentando altos erros e valores negativos de R^2 em horizontes mais longos.

Todos os modelos permaneceram dentro da viabilidade para tarefas em lote ou previsão

Tabela 3: Desempenho dos modelos no horizonte de 1h para as turbinas do ES e RS

Modelo	MAE (W)		RMSE (W)	
	ES	RS	ES	RS
MLP	49.63 ± 10.02	139.74 ± 6.44	68.46 ± 14.82	194.50 ± 9.79
Random Forest	44.99 ± 8.40	157.36 ± 23.69	62.82 ± 13.81	208.01 ± 23.26
Gradient Boosting	44.04 ± 8.49	150.30 ± 17.83	62.48 ± 13.97	210.49 ± 28.89
XGBoost	45.44 ± 9.64	152.79 ± 18.88	64.58 ± 15.84	211.89 ± 24.81
LightGBM	44.82 ± 10.11	145.35 ± 11.70	64.03 ± 16.39	202.40 ± 15.17
LSTM	46.41 ± 10.62	161.92 ± 18.51	65.34 ± 17.13	243.33 ± 35.58
GRU	44.80 ± 9.88	164.43 ± 16.77	63.72 ± 15.94	243.97 ± 35.04
TCN	42.71 ± 8.71	131.76 ± 8.26	59.66 ± 12.88	187.56 ± 13.16
Transformer	45.58 ± 11.03	147.64 ± 15.94	64.78 ± 17.24	205.15 ± 18.60

operativa *offline*, reforçando sua aplicabilidade prática mesmo em cenários de alta frequência conforme apontado em [Lydia et al., 2014; Zame et al., 2018; Wang et al., 2016; Werno e Ziel, 2020] No ES, o LightGBM foi o mais rápido, com apenas 1.68s, enquanto o TCN apresentou o maior tempo, chegando a 416.93s. No RS, os tempos seguiram padrão semelhante: LightGBM manteve a execução mais eficiente (1.12s) e o TCN novamente foi o mais custoso, com 111.18s. Modelos neurais como LSTM e GRU também demandaram tempos elevados em ambas as regiões, refletindo maior complexidade computacional. Todos os experimentos foram realizados no Jupiter Notebook em um computador Macbook Air 2023, chip Apple M2 com 8GB de memória RAM.

3.2. Teste de Wilcoxon

Para avaliar a significância estatística das diferenças de desempenho entre os modelos, foi aplicado o teste de Wilcoxon pareado sobre os valores de erro (RMSE) obtidos via validação cruzada temporal. Para efeito de demonstração, o teste foi conduzido entre os três modelos com melhor desempenho em cada região: TCN, Gradient Boosting e Random Forest no Espírito Santo (ES); e TCN, MLP e LightGBM no Rio Grande do Sul (RS), considerando o horizonte de 1h. Os testes foram realizados para cada par de modelos, com base nos cinco *folds* de validação. Os resultados, resumidos na Tabela 4, indicam que não houve diferenças estatisticamente significativas ($p > 0,05$) entre os modelos comparados, embora alguns pares tenham apresentado valores próximos ao limiar (por exemplo, TCN vs. Gradient Boosting). Isso sugere que, no horizonte de 1 hora, os modelos com melhor desempenho apresentaram resultados estatisticamente semelhantes. Em horizontes mais longos (2h a 6h), observou-se um padrão semelhante, com poucos casos de p-valores próximos da significância ($p < 0,1$), especialmente envolvendo o modelo TCN. Apesar das diferenças numéricas nas métricas, os resultados reforçam a dificuldade em estabelecer superioridade estatística robusta entre os modelos, com base no conjunto de dados e configuração experimental utilizados.

4. Conclusões

Este estudo avaliou o desempenho de diferentes algoritmos de aprendizado de máquina para previsão de potência eólica de curto prazo, utilizando dados reais de duas turbinas localizadas em regiões climáticas distintas do Brasil (Espírito Santo e Rio Grande do Sul). Foram analisados modelos de ensemble e redes neurais profundas, com validação cruzada temporal e métricas padrão (RMSE, MAE e R^2). Os resultados demonstraram que o modelo TCN apresentou o melhor desempenho preditivo em ambas as regiões para o horizonte de 1 hora, com redução de até 3,6% no RMSE em relação ao segundo melhor modelo. Por outro lado, o LightGBM destacou-se pelo menor tempo de inferência, sendo até 99 vezes mais rápido que o TCN, o que o torna uma escolha prática para aplicações com restrições computacionais.

Tabela 4: Teste de Wilcoxon entre os três melhores modelos de cada região (ES e RS) para o horizonte de 1h usando RMSE

Região	Modelo A	Modelo B	p-valor	Significativo
ES	TCN	Gradient Boosting	0.0625	Não
ES	TCN	Random Forest	0.0625	Não
ES	Gradient Boosting	Random Forest	0.5625	Não
RS	TCN	MLP	0.0625	Não
RS	TCN	LightGBM	0.0625	Não
RS	MLP	LightGBM	0.1875	Não

Apesar das diferenças numéricas entre os modelos, o teste de Wilcoxon não identificou diferenças estatisticamente significativas nos erros preditivos, sugerindo desempenho estatisticamente semelhante entre os algoritmos considerados. Essa ausência de significância pode estar associada à alta variabilidade dos dados, ao número limitado de *folds* ($n = 5$) e à quantidade reduzida de amostras, especialmente no RS. Além disso, o uso de uma única métrica pode limitar a capacidade de capturar nuances importantes do comportamento preditivo em diferentes cenários.

Todos os modelos avaliados demonstraram viabilidade operacional para execução em lote ou ambientes offline, e os métodos de menor complexidade — como LightGBM e Random Forest — mostraram-se particularmente atrativos por aliar bom desempenho preditivo com elevada eficiência computacional, o que favorece sua adoção em sistemas embarcados ou com infraestrutura limitada.

Entre as limitações do presente estudo destacam-se o número restrito de turbinas analisadas e a ausência de previsões meteorológicas externas como variáveis exógenas; a aplicação de abordagens de previsão multi-horizonte com modelos do tipo *multi-output*; o uso de testes estatísticos adicionais (e.g., Friedman e Nemenyi) e medidas de efeito como Cliff's Delta; a experimentação com modelos híbridos (estatístico-físicos ou ensemble stacking); a incorporação de previsões meteorológicas de curto prazo (e.g., WRF) como variáveis exógenas; a adoção de estratégias de aprendizado contínuo para adaptar os modelos a mudanças sazonais, e por fim, o uso de GPUs para reduzir os tempos computacionais.

Em síntese, este trabalho reforça o potencial dos modelos de aprendizado de máquina na previsão eólica de curto prazo e destaca que, embora diferenças numéricas sejam observadas, a obtenção de ganhos estatisticamente robustos requer maior diversidade de dados e abordagens. A abordagem proposta pode ser incorporada em sistemas de gestão de energia em microrredes escolares e comunitárias, auxiliando na tomada de decisão para uso otimizado de fontes renováveis.

Agradecimentos

Os autores agradecem a FAPES/UnAC (Nº FAPES 1228/2022 P 2022-CD0RQ, Nº SI-AFEM 2022-CD0RQ) pelo apoio financeiro dado por meio do Sistema UniversidaES, o projeto FAPES 850/2023 - P:2023-DLP0J e o Laboratório Espaço Energia do IFES Serra-ES pela coleta dos dados meteorológicos e de geração eólica.

Referências

- Associação Brasileira de Energia Eólica (2023). Boletim anual de geração eólica 2023. URL <https://abeeolica.org.br/>.
- Bergmeir, C. e Benítez, J. M. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120:70–83.
- Bontempi, G., Taieb, S. B., e Le Borgne, Y.-A. (2012). Machine learning strategies for time series forecasting. In *European Business Intelligence Summer School*, p. 62–77. Springer.
- Cerqueira, V., Torgo, L., e Mozetič, I. (2020). Evaluating time series forecasting models: An empirical study on performance estimation methods. *Machine Learning*, 109(11):1997–2028.
- Council, G. W. E. (2023). Global wind report 2023. <https://gwec.net/global-wind-report-2023/>.
- e Silva, D. P., Salles, J. L. F., Fardin, J. F., e Pereira, M. M. R. (2020). Management of an island and grid-connected microgrid using hybrid economic model predictive control with weather data. *Applied Energy*, 278:115581. ISSN 03062619. URL <https://doi.org/10.1016/j.apenergy.2020.115581>.
- e Silva, D. P., Salles, J. L. F., Fardin, J. F., Pereira, M. M. R., Ottz, V. C., da Silva, F. B., e Pignaton, E. G. (2021). Measured and forecasted weather and power dataset for management of an island and grid-connected microgrid. *Data in Brief*, 39:107513. ISSN 23523409.
- Enersud (2024). Geradores eólicos residenciais. <https://www.enersud.com.br>. Acesso em: mar. 2024.
- Guaitolini, T. M., Nascimento, E. B., Breder, R. P., Gobbi, R. E., e Silva, D. P., Silva, F. B. B., e Camargo, R. S. (2023). Load curve based on modeling a photovoltaic system, load and weather data - a case study in brazil. In *2023 15th IEEE International Conference on Industry Applications (INDUSCON)*, p. 248–253. IEEE. ISBN 979-8-3503-1418-2.
- Jacobson, M. e Delucchi, M. (2011). Providing all global energy with wind, water, and solar power, part i: Technologies, energy resources, quantities and areas of infrastructure, and materials. *Energy Policy*, 39(3):1154–1169.
- Kim, J. e Park, S. (2023). A short-term forecasting of wind power outputs based on gradient boosting machine. *Energies*, 16(3):1132.
- Li, X. e Zhang, Y. (2022). Short-term wind power prediction based on lightgbm and mic. *Energies*, 15(17):6287.
- Li, X. e Zhao, Y. (2023). A temporal-based transformer model for wind power forecasting. *Energy Reports*, 9:567–578.

- Li, X., Li, K., Shen, S., e Tian, Y. (2023). Exploring time series models for wind speed forecasting: A comparative analysis. *Energies*, 16(23). ISSN 1996-1073. URL <https://www.mdpi.com/1996-1073/16/23/7785>.
- Liu, J. e Zhang, X. (2023). Boosted gru model for short-term forecasting of wind power with wpca and pso. *Energy*, 267:125503.
- Liu, Z., Guo, H., Zhang, Y., e Zuo, Z. (2025). A comprehensive review of wind power prediction based on machine learning: Models, applications, and challenges. *Energies*, 18(2):350.
- Lundberg, S. M. e Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30:4765–4774.
- Lydia, M., Kumar, S. S., Selvakumar, A. I., e Prem Kumar, G. (2014). A comprehensive review on wind turbine power curve modeling techniques. *Renewable and Sustainable Energy Reviews*, 30: 452–460.
- Manwell, J. F., McGowan, J. G., e Rogers, A. L. (2010). *Wind Energy Explained: Theory, Design and Application*. Wiley. ISBN 978-0-470-01500-1.
- Reddy, P. e Kumar, V. (2024). Wind power prediction using optimized mlp-nn machine learning model. *Electrical Engineering*, 106(2):123–135.
- Wang, J., Qin, Q., Zhang, Z., e Ding, Y. (2016). Wind power forecasting using machine learning: A review. *Renewable and Sustainable Energy Reviews*, 56:368–381.
- Wang, Y. e Zhao, K. (2023). Wind power short-term forecasting method based on lstm and self-moving window. *Sustainability*, 15(4):3798.
- Werno, M. e Ziel, F. (2020). Machine learning methods for short-term prediction of photovoltaic power. *Renewable Energy*, 148:1099–1110.
- Zame, K. K., Brehm, R., Nitica, A., Richard, C., e Schweikert, A. (2018). Smart grid and renewable energy integration: A review and future directions. *Renewable and Sustainable Energy Reviews*, 82:2379–2395.
- Zhang, Y. e Liu, S. (2022). Wind power forecasting based on new hybrid model with tcn and vmd. *Energy Reports*, 8:1234–1245.
- Zhao, Y., Chen, M., e Wang, X. (2021). Interpretable machine learning for smart grid: Applications and challenges. *IEEE Access*, 9:18006–18022.
- Zheng, H. e Wu, Y. (2019). A xgboost model with weather similarity analysis and feature engineering for short-term wind power forecasting. *Applied Sciences*, 9(15):3019.