



ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Modelo Combinado Utilizando Otimização Multi-Objetivo Para Previsão de Dados Eólicos

Doglas Querino dos Anjos

PPGEPS - Pontifícia Universidade Católica do Paraná (PUCPR)

Gilberto Reynoso-Meza

PPGEPS - Pontifícia Universidade Católica do Paraná (PUCPR)

Resumo: Este artigo propõe um modelo combinado que integra as arquiteturas Informer, Autoformer e Transformer, utilizando a otimização multiobjetivo baseada no algoritmo NSGA-III para prever dados eólicos. Os dados utilizados no estudo foram fornecidos pela UTFPR. O estudo foi conduzido em duas abordagens distintas: a primeira sem a aplicação de técnicas de denoising e a segunda com a aplicação de denoising utilizando a Empirical Mode Decomposition (EMD), com o objetivo de melhorar a precisão das previsões. Para ambas as abordagens, o processo de otimização foi realizado considerando dois objetivos principais: o erro quadrático médio (RMSE) e a porcentagem de erro absoluto médio (MAPE). Os resultados experimentais demonstraram que o modelo combinado oferece maior estabilidade e robustez em comparação com as versões individuais de Informer, Autoformer e Transformer. Além disso, a abordagem que incorporou o denoising por meio da EMD apresentou uma performance significativamente melhor, evidenciando a importância da remoção de ruídos nas séries temporais eólicas. O modelo com denoising utilizando EMD superou a abordagem sem denoising e demonstrou sua eficácia em tarefas de otimização multiobjetivo, especialmente para a previsão de séries temporais de dados eólicos.

Palavras-chave: Informer, Autoformer, Transformer, Otimização Multiobjetivo, Denoising.

Hybrid Model Using Multi-Objective Optimization for Wind Data Forecasting

Abstract: This paper proposes a combined model integrating the Informer, Autoformer, and Transformer architectures, using multi-objective optimization based on the NSGA-III algorithm to forecast wind data. The data used in the study were provided by UTFPR. The study was conducted in two distinct approaches: the first without the application of denoising techniques, and the second with denoising using Empirical Mode Decomposition (EMD), aimed at improving prediction accuracy. For both approaches, the optimization process focused on two main objectives: Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE). The experimental results demonstrated that the combined model offers greater stability and robustness compared to the individual Informer, Autoformer, and Transformer models. Moreover, the approach incorporating EMD-based denoising showed significantly improved performance, highlighting the importance of noise removal in wind time series data. The model with EMD denoising outperformed the approach without denoising and proved its effectiveness in multi-objective optimization tasks, particularly for wind data time series forecasting.

Keywords: Informer, Autoformer, Transformer, Multi-objective Optimization, Denoising.

1. Introdução

A integração da energia eólica na rede elétrica apresenta grandes desafios em comparação com a eletricidade gerada de forma convencional, principalmente devido à volatilidade intrínseca do vento. Essa variabilidade impacta tanto o controle das turbinas quanto a operação eficiente da rede elétrica, sendo que o foco principal está na previsão de comportamento do vento para garantir a estabilidade do sistema. A previsão precisa de dados eólicos é fundamental para otimizar o despacho econômico de usinas convencionais, com horizontes de previsão que podem variar de 3 a 10 horas, dependendo do tipo de unidade geradora envolvida. Embora as aplicações totalmente integradas de previsão ainda sejam raras em sistemas de grande escala, alguns países como estão avaliando essas soluções para otimizar a operação de redes isoladas e de maior porte. O desenvolvimento de modelos avançados para a previsão de energia eólica, portanto, tornou-se uma área chave de pesquisa, visando melhorar a precisão das previsões e reduzir a incerteza inerente aos dados eólicos (Kariniotakis, 2017).

Modelos baseados em Transformers têm se destacado na previsão de séries temporais devido à sua capacidade de capturar dependências de longo prazo. No entanto, enfrentam desafios significativos em previsões de longas sequências, como alto custo computacional e problemas de memória. Novas abordagens, como o Informer, foram desenvolvidas para superar essas limitações, otimizando o uso de auto-atenção (self-attention) e melhorando a eficiência no processamento de grandes volumes de dados temporais, o que torna esses modelos promissores para aplicações complexas de previsão em larga escala (Zhou, et al., 2021).

A otimização multiobjetivo (MOO) tem se mostrado uma ferramenta valiosa para resolver problemas complexos que envolvem múltiplos critérios de desempenho, especialmente em cenários onde esses objetivos são conflitantes. Ao invés de buscar uma única solução ótima, a MOO busca um conjunto de soluções de compromisso, também conhecido como fronteira de Pareto, onde cada solução representa um trade-off entre diferentes objetivos. Essa abordagem é amplamente utilizada em engenharia de controle, aprendizado de máquina e problemas industriais, onde as soluções geradas podem otimizar simultaneamente diversas variáveis, como erro, tempo e custo (Meza, et al., 2014). A principal vantagem da MOO está na sua capacidade de explorar e apresentar várias soluções não dominadas, permitindo ao tomador de decisão escolher a mais adequada de acordo com suas preferências e restrições específicas. Além disso a MOO pode ser adaptada para fornecer uma visão clara das interações entre objetivos conflitantes, facilitando decisões mais informadas (Ribeiro; Meza, 2019).

Este artigo está estruturado em sete seções. A Seção 2 apresenta uma revisão bibliográfica das ferramentas e conceitos utilizados ao longo do estudo. A Seção 3 descreve os dados e a metodologia adotada. Na Seção 4, são expostos os resultados e a discussão. A Seção 5 contém a conclusão, enquanto a Seção 6 fornece a revisão bibliográfica. Por fim, a Seção 7 apresenta os agradecimentos.

2. Revisão Bibliográfica

Esse capítulo é destinado a apresentar uma revisão bibliográfica dos diversos algoritmos utilizados nesse artigo.

2.1 Transformer

A revisão sobre o uso de Transformers em séries temporais abrange suas inovações e adaptações no contexto de modelagem de dados sequenciais, com foco em previsão, detecção de anomalias e classificação. As principais vantagens dos Transformers incluem a capacidade de capturar dependências de longo alcance, uma característica particularmente útil em séries temporais que apresentam padrões sazonais e de tendência. O Transformer, originalmente desenvolvido para processamento de linguagem natural, foi adaptado para tarefas temporais com melhorias em sua codificação posicional e nos módulos de auto-atenção (self-attention). Em comparação com modelos tradicionais, como ARIMA e RNNs, os Transformers demonstram uma performance superior em tarefas de previsão de longo prazo, principalmente devido à sua habilidade de processar entradas simultâneas de diversas posições temporais e identificar relações complexas nos dados temporais (Wen, et al., 2023).

2.2 Autoformer

O Transformer tradicional, com sua capacidade de atenção automática, é eficaz para capturar dependências de longo alcance em dados sequenciais. No entanto, apresenta limitações, como a alta complexidade computacional devido ao cálculo quadrático em relação ao comprimento da sequência. O Autoformer, por outro lado, propõe uma arquitetura de decomposição que resolve essa limitação ao introduzir blocos de decomposição de séries e um mecanismo de autocorrelação. Isso permite que o Autoformer identifique padrões periódicos nos dados temporais, agregando informações de subséries semelhantes e melhorando tanto a eficiência quanto a precisão da previsão. Os resultados experimentais mostraram que o Autoformer supera modelos anteriores em termos de redução de erro médio quadrático (MSE) e erro absoluto médio (MAE) em diversos conjuntos de dados, como consumo de energia, tráfego e dados meteorológicos (Wu, et al., 2022).

Autoformer também se destaca ao lidar com a complexidade das séries temporais, particularmente em cenários com padrões intrincados e interações temporais de longo prazo. Enquanto outros modelos baseados em Transformers utilizam versões esparsas da auto-atenção (self-attention) para melhorar a eficiência, a arquitetura do Autoformer oferece vantagens claras sobre modelos anteriores, não apenas em termos de precisão, mas também de robustez em cenários de previsão de longo prazo, destacando-se em aplicações como planejamento energético, tráfego e previsão meteorológica (Wu, et al., 2022).

2.3 Informer

O Informer se destaca ao abordar as principais dificuldades do modelo Transformer padrão, como a complexidade quadrática de tempo e uso de memória devido ao mecanismo de auto-atenção (self-attention), que é problemático para séries temporais de grande escala. O Informer propõe inovações como o mecanismo de auto-atenção (self-attention) esparsa (ProbSparse) que reduz significativamente o custo computacional e a memória necessários, atingindo uma complexidade de $O(L \log L)$, onde L é o comprimento da sequência e O a complexidade de tempo e memória. Além disso, o Informer introduz um decodificador generativo, que realiza previsões de longo prazo em uma única operação de inferência, eliminando a necessidade de decodificação dinâmica e reduzindo o acúmulo de erros ao longo das previsões (Zhou, et al., 2021).

O Informer supera modelos anteriores em diversos conjuntos de dados de larga escala, demonstrando melhor desempenho em termos de erro quadrático médio (MSE) e erro

absoluto médio (MAE). O modelo também mostra uma estabilidade superior em cenários de previsão multivariada de longo prazo, quando comparado a modelos como o Reformer e o LogSparse Transformer (Zhou, et al., 2021).

2.4 RMSE

O Root Mean Square Error (RMSE) é amplamente utilizado em estudos de modelagem no campo das geociências, como meteorologia e hidrologia, sendo particularmente útil em cenários onde os erros seguem uma distribuição normal (gaussiana). O cálculo do RMSE envolve a raiz quadrada da média dos erros quadrados, o que dá mais peso a grandes erros, sendo adequado para situações em que grandes desvios são considerados mais prejudiciais. Além disso, o RMSE tem a vantagem de estar na mesma unidade dos dados originais, facilitando a interpretação dos resultados (Hodson, 2022). Abaixo está apresentado a fórmula para cálculo do RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (1)$$

2.5 MAPE

O MAPE é uma das métricas mais populares por sua simplicidade e independência de escala, sendo amplamente utilizada em previsões de negócios e em várias áreas de estudo. No entanto, o MAPE apresenta problemas consideráveis, como a produção de valores infinitos ou indefinidos quando os valores reais são zero ou próximos de zero. Em cenários com demanda intermitente, como em varejo ou finanças, isso pode gerar grandes distorções nos resultados das previsões. Além disso, o MAPE pode ser enviesado para previsões que subestimam os valores reais, já que a métrica tende a penalizar mais fortemente erros positivos em comparação aos negativos (Kim; Kim, 2016). Abaixo está apresentado a fórmula para cálculo do MAPE:

$$MAPE = \frac{1}{n} \sum_{j=1}^N \left| \frac{(y_j - \hat{y}_j)}{y_j} \right| \quad (2)$$

2.6 EMD e Denoising

Na revisão de estratégias de processamento de dados para previsão de energia eólica, a decomposição empírica (EMD) e o denoising baseado em decomposição emergem como técnicas cruciais para melhorar a precisão das previsões. A decomposição empírica de modos (EMD) é amplamente utilizada por sua capacidade de adaptar-se a sinais não estacionários, decompondo séries temporais em funções de modo intrínseco (IMFs). Essas funções permitem capturar as variações locais de frequência de dados como a velocidade do vento, facilitando uma análise mais detalhada dos padrões (Liu; Chen, 2019).

Um aspecto chave para decomposição utilizando EMD é o uso da primeira função de modo intrínseco (IMF1), frequentemente associada a componentes de alta frequência que podem conter tanto informações úteis quanto ruído. O IMF1 é altamente volátil e pode prejudicar a previsibilidade do modelo. Por esse motivo, muitos modelos optam por descartar o IMF1 durante o processo de decomposição, tratando-o como ruído. Ao remover essa componente, a série temporal torna-se mais estável e previsível, resultando em melhorias significativas na precisão da previsão (Liu; Chen, 2019).

2.7 MOOD

O processo de design de MOO consiste em três etapas principais, que são cruciais para resolver problemas com múltiplos objetivos conflitantes: (a) Definição do Problema Multiobjetivo (MOP), (b) Otimização Multiobjetivo (MOO) propriamente dita, e (c) Método de Decisão Multicritério (MCDM) (Ribeiro; Meza, 2019).

- a) Definição do Problema Multiobjetivo (MOP): O primeiro passo é a formulação correta do problema, onde os objetivos a serem maximizados ou minimizados são expressos como um vetor de funções objetivo $J(x) = [J_1(x), J_2(x), \dots, J_m(x)]$, onde m é o número de objetivos a serem otimizados. O vetor de decisão $x = [x_1, x_2, \dots, x_n]$ representa as variáveis de decisão, com n sendo o número total de variáveis. Essas variáveis estão sujeitas a restrições que podem ser descritas por vetores de inequidade $K(x) \leq 0$ e vetores de equidade $L(x) = 0$, que limitam o espaço de solução viável. Além disso, o vetor de decisão x está restrito a limites inferiores e superiores, $x_l \leq x_i \leq x_u$, que definem a faixa admissível de valores que cada variável de decisão pode assumir. A formulação adequada desse problema permite a busca por soluções que equilibrem os múltiplos objetivos, resultando em soluções não dominadas, as quais compõem a fronteira de Pareto, onde nenhuma solução pode ser melhorada em um objetivo sem piorar outro (Ribeiro; Meza, 2019);
- b) Otimização Multiobjetivo (MOO): Nesta fase, são aplicadas técnicas de otimização para encontrar soluções não dominadas, ou seja, soluções que não podem ser melhoradas em um dos objetivos sem piorar em outro. Ferramentas como o NSGA-II (Algoritmo Genético de Ordenação Não Dominada), MOEA/D (Algoritmo Evolutivo de Decomposição Multiobjetivo), e o spMODE-II (Multi-Objective Differential Evolution) são amplamente utilizadas para gerar a aproximação da fronteira de Pareto. Essas soluções são representadas em um espaço onde é possível visualizar os trade-offs entre os diferentes objetivos (Ribeiro; Meza, 2019);
- c) Método de Decisão Multicritério (MCDM): Após a otimização, o próximo passo é a seleção da solução mais adequada dentre as obtidas na fronteira de Pareto. O MCDM utiliza ferramentas como índices baseados em preferências (PP) e coordenadas paralelas para auxiliar os tomadores de decisão na escolha da solução que melhor atende às suas prioridades e restrições. Esse processo de visualização e ranking permite focar em uma região preferível da fronteira de Pareto, considerando os trade-offs entre os diferentes objetivos de forma visual e interpretativa (Ribeiro; Meza, 2019);

Esse processo estruturado possibilita a criação de soluções robustas e balanceadas em problemas complexos, permitindo a análise profunda das interações entre múltiplos objetivos conflitantes e oferecendo uma base sólida para a tomada de decisões

2.8 NSGA-III

O NSGA-III (Nondominated Sorting Genetic Algorithm III) é um algoritmo de MOO projetado para lidar com muitos objetivos simultaneamente. Ele se baseia nos seguintes princípios:

- a) Pontos de Referência: O NSGA-III utiliza pontos de referência, distribuídos uniformemente em um hiperplano, para garantir que as soluções sejam bem distribuídas na fronteira de Pareto.
- b) Classificação por Não-Dominância: As soluções são organizadas em níveis de não-dominância, e as melhores são selecionadas para formar a próxima geração.
- c) Normalização e Associação: As soluções são normalizadas em relação a um ponto ideal e associadas ao ponto de referência mais próximo, garantindo diversidade nas soluções.

- d) Operadores Genéticos: Crossover e mutação são usadas para gerar novas soluções, preservando a diversidade no conjunto de soluções.

O NSGA-III é eficiente em lidar com problemas de muitos objetivos, garantindo soluções bem distribuídas e equilibradas (Deb; Jain, 2014).

2.9 Multi-Criteria Decision Making

Na otimização multiobjetivo, o ponto ideal e o ponto nadir são referências fundamentais para a avaliação de soluções na fronteira de Pareto. O ponto ideal representa os melhores valores possíveis para cada critério, enquanto o ponto nadir indica os piores valores para cada objetivo entre as soluções não dominadas. Esses dois pontos ajudam a definir os limites do espaço de decisão, permitindo ao decisor entender os possíveis trade-offs entre os objetivos (Blank, 2020).

Os pseudo weights são uma técnica utilizada em otimização multiobjetivo para guiar a seleção de soluções na fronteira de Pareto, ajustando dinamicamente os pesos durante o processo de tomada de decisão, com base nas preferências do decisor e nas características das soluções. Diferentemente dos pesos fixos tradicionais, os pseudo weights são calculados de forma a refletir a distância normalizada da pior solução em relação a cada objetivo (Blank, 2020).

A fórmula apresentada na imagem define o cálculo do pseudo peso ω_i para a $i_{ésima}$ função objetivo:

$$\omega_i = \frac{\frac{f_i^{max} - f_i(x)}{f_i^{max} - f_i^{min}}}{\sum_{m=1}^M \frac{f_m^{max} - f_m(x)}{f_{im}^{max} - f_m^{min}}} \quad (3)$$

Onde:

- $f_i(x)$ é o valor da $i_{ésima}$ função objetivo para a solução x ;
- f_i^{max} e f_i^{min} são os valores máximo e mínimo da $i_{ésima}$ função objetivo;
- O denominador normaliza a distância em relação à soma total das funções objetivo M , garantindo que o peso relativo de cada objetivo seja ajustado com base na distribuição das soluções;

Os pseudo weights servem para guiar a busca por soluções que estejam mais próximas do ponto ideal, minimizando a distância relativa em relação ao ponto nadir. Ao normalizar a distância de cada objetivo, os pseudo weights ajustam as preferências do decisor, garantindo que a solução final reflita um equilíbrio adequado entre os critérios. Em problemas com uma fronteira de Pareto convexa, os pseudo weights ajudam a indicar diretamente a posição das soluções no espaço de decisão, enquanto em frentes não convexas, eles facilitam a exploração de regiões mais complexas da fronteira, sem necessariamente corresponder a uma soma ponderada convencional (Suresh; Deb, 2024).

3. Dados e Metodologia

3.1 Dados:

Os dados utilizados foram fornecidos pela Universidade Tecnológica Federal do Paraná (UTFPR) que foram gerados em um estudo amplo voltado para a construção de um mapa de potencial eólico na Região Metropolitana de Curitiba (RMC). Em particular, foram utilizados os dados coletados pela torre anemométrica instalada na Lapa, uma das cinco torres posicionadas pela UTFPR. Esses dados refletem características de um ambiente urbano e semiurbano (Vieira, 2020).

As torres foram posicionadas em locais estratégicos, considerando a topografia e as condições geográficas, para fornecer dados precisos e confiáveis. A Torre da Lapa foi equipada com sensores instalados a 30 metros de altura para medir a velocidade e a direção do vento, além de outros parâmetros meteorológicos como pressão, temperatura e umidade relativa (Vieira, 2020).

3.2 Metodologia

Foi desenvolvido um modelo combinado utilizando Informer, Autoformer e Transformer, treinados para prever 25 passos à frente nos dados, onde cada passo corresponde a 10 minutos de intervalo. Para o treinamento de cada modelo, foi estabelecido que o erro de treinamento (train error loss) deveria ser inferior a 0.3. O conjunto de dados utilizado para cada treino continha 432 amostras, o que equivale a 3 dias de dados. Foram realizadas 100 rodadas de treinamento e previsão para cada modelo, com a janela de dados sendo movida uma hora à frente a cada rodada.

Após o treinamento dos modelos individuais, foi aplicada a MOO utilizando o algoritmo NSGA-III para criar um modelo combinado. O objetivo da otimização foi encontrar a melhor relação de pesos entre os três modelos, minimizando duas funções objetivo: MAPE e RMSE. A fórmula do modelo combinado é dada por:

$$Modelo\ Combinado = \frac{\omega_1 * Previsão_{Informer} + \omega_2 * Previsão_{Autoformer} + \omega_3 * Previsão_{Transformer}}{\omega_1 + \omega_2 + \omega_3} \quad (4)$$

onde ω_1 , ω_2 e ω_3 são os pesos atribuídos às previsões dos três modelos. Os limites impostos para os pesos na otimização foram definidos como:

$$0 \leq \omega_1, \omega_2, \omega_3 \leq 1 \quad (4)$$

Em seguida, foi criado um segundo modelo utilizando denoising baseado em EMD para limpar os dados de treino antes de treinar os modelos Informer, Autoformer e Transformer. Após a limpeza dos dados com EMD, o mesmo processo de otimização multiobjetivo foi repetido.

O problema MOO foi definido como:

Vetor de Decisão: O vetor de decisão x é composto pelos pesos atribuídos a cada modelo, ou seja:

$$X = [\omega_1, \omega_2, \omega_3] \quad (5)$$

Vetor de Funções Objetivo: O vetor de funções objetivo, a ser minimizado pela otimização NSGA-III, é expresso como:


$$J(x) = [MAPE(x), RMSE(x)] \quad (6)$$

Onde $MAPE(x)$ e $RMSE(x)$ representam as funções objetivo que calculam o erro percentual médio absoluto e o erro quadrático médio, respectivamente, em função dos pesos ω_1 , ω_2 e ω_3 .

Após a otimização multiobjetivo, foi gerada uma frente de Pareto. Para selecionar a solução mais adequada dentro dessa fronteira, utilizou-se a abordagem dos pseudo weights, que foram configurados com valores de 0.5 para MAPE e 0.5 para RMSE, indicando uma preferência equilibrada entre os dois critérios. Dessa forma, a melhor combinação de pesos para os modelos foi determinada de modo a proporcionar um equilíbrio adequado entre MAPE e RMSE.

Abaixo é apresentada uma figura da fronteira de Pareto gerada em uma das rodadas de otimização, juntamente com a seleção do ponto ideal:

Figura 1 – Frente de Pareto com identificação do ponto ótimo para uma das rodadas de previsão.



Fonte: Autor (2024)

4. Resultados e Discussões

A análise dos resultados revelou que o Modelo Combinado se destacou como a melhor opção em ambas as abordagens (com e sem denoising), apresentando o menor valor acumulado na avaliação dos pesos, o que reflete seu desempenho superior em relação aos outros modelos. O ranking dos modelos demonstrou que o Modelo Combinado foi consistentemente melhor, enquanto o Autoformer apresentou o pior desempenho geral nas comparações.

Tabela 1 – Pontuação por modelo, comparação dos modelos utilizando denoising.

Modelos	Sem Denoising	Com Denoising
Combinado	433	417
Transformer	465	473
Informer	475	493
Autoformer	627	617

Fonte: Autor (2024)

Tabela 2 – Diferença percentual entre modelo combinado e demais modelos.

Modelos	Sem Denoising	Com Denoising
Transformer	7.13 %	12.47 %
Informer	9.25 %	16.74 %
Autoformer	36.60 %	37.74 %

Fonte: Autor (2024)

Além disso, ao incluir a técnica de denoising baseada em EMD, foi observado um benefício adicional para o Modelo Combinado. A tabela de resultados mostra que o modelo com denoising não apenas manteve a liderança no ranking, como também apresentou maior estabilidade em todas as rodadas de avaliação, evidenciada por uma variação mais uniforme nos pesos atribuídos. Visualmente, a análise dos pesos atribuídos sugere que o denoising contribuiu para um desempenho mais estável, minimizando as oscilações observadas em outros modelos.

Os dados também indicam que o denoising teve impacto positivo em todos os modelos, mas foi especialmente benéfico para o Modelo Combinado, que obteve uma melhora percentual expressiva em comparação com a versão sem denoising. Ao comparar os resultados percentuais, o modelo com denoising superou os demais com uma margem clara, reforçando sua vantagem tanto em precisão quanto em estabilidade ao longo do tempo.

5. Conclusões

Com base nos resultados obtidos e na revisão bibliográfica, foi possível concluir que o Modelo Combinado apresentou um desempenho superior em relação aos modelos individuais (Informer, Transformer e Autoformer), especialmente quando a técnica de denoising baseada em Empirical Mode Decomposition (EMD) foi aplicada. Através da otimização multiobjetivo, com as funções objetivo MAPE e RMSE, o modelo combinado alcançou uma melhor relação de pesos, evidenciada tanto pela maior precisão quanto pela estabilidade em todas as rodadas de avaliação.

A análise dos rankings revelou que o Modelo Combinado, sem e com denoising, se destacou em ambas as situações. No entanto, a aplicação do denoising proporcionou uma melhoria ainda mais expressiva, reduzindo a variabilidade dos erros e tornando o modelo mais robusto em diferentes cenários de previsão. O denoising também se mostrou eficaz na suavização dos dados, o que resultou em um melhor ajuste dos modelos aos dados de treino, conforme evidenciado pela análise visual dos pesos atribuídos aos modelos.

A partir da revisão bibliográfica, foi possível observar que a combinação de modelos e o uso de técnicas de denoising são abordagens amplamente recomendadas para melhorar a previsão de séries temporais em cenários complexos. O uso do ponto ideal e do ponto nadir, juntamente com os pseudo weights, permitiu que a otimização fosse guiada para a seleção de soluções equilibradas na fronteira de Pareto, conforme destacado em estudos anteriores. A abordagem utilizada neste trabalho reflete os avanços da literatura e comprova a eficácia de combinar técnicas modernas de previsão, otimização multiobjetivo e denoising, culminando em um modelo preditivo mais preciso e estável.

Dessa forma, o estudo demonstra a relevância de adotar estratégias híbridas e avançadas para a previsão de dados eólicos, fornecendo uma base sólida para futuras pesquisas no campo da previsão de séries temporais com múltiplos modelos.

6. Referências

- Blank, J. (2020). Part III: **Multi-Criteria Decision Making**. Fonte: PYMOO: https://pymoo.org/getting_started/part_3.html
- Deb, K., & Jain, H. (Agosto de 2014). **An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point-Based Nondominated Sorting Approach**, Part I: Solving Problems With Box Constraints. IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION, VOL. 18.
- Hodson, T. (2022). **Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not**.
- Kariniotakis, G. (2017). **Renewable Energy Forecasting**. Woodhead Publishing.
- Kim, S., & Kim, H. (2016). **A new metric of absolute percentage error for intermittent demand forecasts**.
- Liu, H., & Chen, C. (2019). **Data processing strategies in wind energy forecasting models and applications: A comprehensive review**. Applied Energy 149 , pp. 392–408.
- Meza, G. R., Blasco, X., Sanchis, J., & Martínez, M. (2014). **Controller tuning using evolutionary multi-objective optimisation: Current trends and applications**. Control Engineering Practice 28, pp. 58-73.
- Ribeiro, V. H., & Meza, G. R. (2019). **A holistic multi-objective optimization design procedure for ensemble member generation and selection**. Applied Soft Computing Journal 83.
- Suresh, A., & Deb, K. (2024). **On a Better Understanding of Unique Identifiers of Pareto Solutions for Multi-criterion Optimization, Visualization, and Decision-making**. Congress on Evolutionary Computation (CEC).
- Vieira, B. J. (2020). **METODOLOGIA PARA ELABORAÇÃO DE MAPA DE POTENCIAL EÓLICO DE REGIÕES METROPOLITANAS**. Dissertação. Curitiba.
- Wen, Q., Zhou, T., Zhang, C., Chen, W., Ma, Z., Yan, J., & Sun, L. (2023). **Transformers in Time Series: A Survey**.
- Wu, H., Xu, J., Wang, J., & Long, M. (2022). Autoformer: **Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting**.
- Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., & Zhang, W. (2021). **Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting**.

7. AGRADECIMENTOS

Os autores agradecem à Companhia Paranaense de Energia Elétrica (COPEL) pelo suporte e financiamento na realização do projeto de pesquisa PD ANEEL 2866-0464/2017 (Metodologia para Análise, Monitoramento e Gerenciamento da Geração Distribuída por Fontes Incentivadas), e à Companhia de Saneamento do Paraná (Sanepar) pela cessão dos espaços e apoio no processo de instalação das torres.

Este Estudo foi financiado em partes pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) através do projeto PQ-2/310195/2022-5 & Universal/408164/2021-2.