UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
CURSO DE BACHARELADO EM METEOROLOGIA

LUANA DO NASCIMENTO VASCONCELOS

CORREÇÃO DE BIAS DA VELOCIDADE DO VENTO DA SAÍDA DO MODELO ATMOSFÉRICO, UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA O ESTADO DE ALAGOAS

Maceió, AL
Maio, 2025

LUANA DO NASCIMENTO VASCONCELOS

CORREÇÃO DE BIAS DA VELOCIDADE DO VENTO DA SAÍDA DO MODELO ATMOSFÉRICO, UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA O ESTADO DE ALAGOAS

Trabalho de Conclusão de Curso apresentado ao Instituto de Ciências Atmosféricas da Universidade Federal de Alagoas, como requisito parcial à obtenção do título de Bacharelado em Meteorologia.

Orientador: Prof. Dr. Rosiberto Salustiano da Silva Junior.

Maceió, AL

2025

Catalogação na Fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

V331c Vasconcelos, Luana do Nascimento.

Correção de bias da velocidade do vento da saída do modelo atmosférico, utilizando inteligência artificial para o estado de Alagoas / Luana do Nascimento Vasconcelos. – 2025.

36 f. : il.

Orientador: Rosiberto Salustiano da Silva Junior.

Monografia (Trabalho de Conclusão de Curso em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2025.

Bibliografia: f. 31-36.

1. Redes neurais (Computação). 2. Modelagem atmosférica. 3. Long short-term memory. 4. Weather research and forecasting. I. Título.

CDU: 004.032.26

Folha de aprovação

LUANA DO NASCIMENTO VASCONCELOS

CORREÇÃO DE BIAS DA VELOCIDADE DO VENTO DA SAÍDA DO MODELO ATMOSFÉRICO, UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA O ESTADO DE ALAGOAS

Trabalho de Conclusão de Curso apresentado ao Instituto de Ciências Atmosféricas - ICAT da Universidade Federal de Alagoas como requisito parcial à obtenção do grau de Bacharel em Meteorologia, aprovado em 20 de maio de 2025.

gov.br Documento assinado digitalmente
ROSIBERTO SALUSTIANO DA SILVA JUNIOR
Data: 13/06/2025 15:38:24-0300
Verifique em https://validar.iti.gov.br

Orientador - Dr. Rosiberto Salustiano da Silva Junior
(Instituto de Ciências Atmosféricas – ICAT/UFAL)

Banca Examinadora:

gov.br Documento assinado digitalmente
HELBER BARROS GOMES
Data: 13/06/2025 16:21:01-0300
Verifique em https://validar.iti.gov.br

Examinador Interno Dr. Helber Barros Gomes
(Instituto de Ciências Atmosféricas – ICAT/UFAL)

gov.br Documento assinado digitalmente
ERICKA VOSS CHAGAS
Data: 16/06/2025 10:30:08-0300
Verifique em https://validar.iti.gov.br

Examinadora Interna Drª. Ericka Voss Chagas
(Instituto de Ciências Atmosféricas – ICAT/UFAL)

Assinado digitalmente por:
Diogo Nunes da Silva Ramos
CPF: ***.300.584-**
Certificado emitido por Ac Senai Bahia
Data: 13/06/2025 17:28:46 -03:00
SENAI

Examinador Externo Dr. Diogo Nunes da Silva Ramos
(Centro Integrado de Manufatura e Tecnologia SENAI/CIMATEC)

Dedico esse trabalho a memória do meu pai, cujo amor permanece vivo em mim. Mesmo que ausente fisicamente, sua lembrança foi minha força nos momentos mais difíceis. Por isso, dedico esse trabalho a mantê-lo vivo em cada linha que eu escrevo.

AGRADECIMENTOS

- Agradeço primeiramente a Deus, por me conceder essa oportunidade e me fortalecer nos momentos mais difíceis dessa trajetória.
- Ao Professor Dr. Rosiberto Salustiano, por toda compreensão, paciência e conversas que não somente contribuíram para o meu desenvolvimento profissional, mas também pessoal.
- A banca examinadora composta por Helber Barros Gomes, Ericka Voss Chagas e Diogo Nunes da Silva Ramos, por todas sugestões e carinho.
- Aos meus familiares por toda motivação e apoio em todos os momentos da minha vida, e aos meus amigos, em especial Suel Cardoso, Luan Santos, Bruno Melo, Ewerton Muniz e Brisa Soriano, por terem sido minha rede de apoio, e sempre estarem por perto nos momentos que mais precisei.
- A UFAL que viabilizou minhas contribuições para a comunidade cientifica.
- Por fim, e não menos importante, por todos os professores do ICAT pelo suporte técnico, científico e humano oferecido ao longo dessa jornada.

RESUMO

Este estudo aborda o refinamento das simulações do recurso velocidade do vento e potencial eólico, utilizando redes neurais artificiais para corrigir erros nas simulações do modelo atmosférico WRF. A crescente participação das energias renováveis na matriz elétrica brasileira reforça a importância de previsões meteorológicas mais precisas para garantir eficiência na geração de energia e minimizar o uso de termelétricas, que possuem impactos ambientais negativos. O estudo utilizou dados de estações anemométricas localizadas em Alagoas para os municípios de Feliz deserto, Girau do Ponciano e Água branca, com dados do período do ano de 2008 para validar a metodologia das simulações com refinamento a partir de redes neurais do tipo LSTM. O modelo híbrido WRF+LSTM foi empregado para corrigir os erros sistemáticos do WRF, utilizando aprendizado profundo para melhorar as estimativas de velocidade do vento à 100 metros de altura. As métricas estatísticas demonstram que o modelo híbrido apresentou melhorias significativas na simulação da velocidade do vento em todas as localidades analisadas. Na estação de Feliz Deserto, a correlação aumentou de 0,56 (WRF) para 0,87 (WRF+LSTM), com redução do viés de 0,50 m/s para –0,15 m/s, e queda no RMSE de 1,59 m/s para 0,72 m/s, além da redução do erro percentual nRMSE de 24% para 11%. Resultados semelhantes foram observados nas estações de Girau do Ponciano e Água Branca, com aumento da correlação de 0,62 para 0,85 e de 0,54 para 0,85, respectivamente. Nessas estações, o RMSE caiu de 2,69 m/s para 1,02 m/s, e de 2,02 m/s para 1,01 m/s, com reduções expressivas no nRMSE (de 31% para 12%, e de 25% para 12%). A abordagem WRF+LSTM melhora significativamente a simulação da velocidade do vento em comparação ao modelo WRF isolado. Essa combinação aprimorou a captura das variações sazonais, especialmente nos períodos de maior intensidade dos ventos. Além disso, destacou-se a capacidade do modelo em representar com maior precisão a influência da circulação de brisa marítima e continental, que afeta significativamente os padrões de vento, bem como os efeitos do relevo acidentado nas dinâmicas atmosféricas. Os resultados indicam que a abordagem híbrida é promissora para otimizar a previsão de geração eólica, melhorando o planejamento e a operação dos parques eólicos. O estudo sugere que a combinação de modelos atmosféricos com redes neurais pode contribuir para a expansão da energia renovável no Brasil, tornando a geração mais eficiente e previsível.

Palavras-chave: Redes neurais artificiais, modelagem atmosférica, LSTM, WRF, refinamento.

ABSTRACT

This study addresses the refinement of wind speed and wind power resource simulations by using artificial neural networks to correct errors in simulations generated by the WRF atmospheric model. The increasing share of renewable energy in Brazil's electricity matrix underscores the importance of more accurate weather forecasts to ensure efficient energy generation and to minimize the use of thermoelectric plants, which have negative environmental impacts. The study used data from anemometric stations located in Alagoas, specifically in the municipalities of Feliz Deserto, Girau do Ponciano, and Água Branca, with data from the year 2008 to validate the simulation methodology refined through LSTM-type neural networks. The hybrid WRF+LSTM model was employed to correct systematic errors of the WRF model, using deep learning to improve wind speed estimates at 100 meters above ground level. Statistical metrics show that the hybrid model presented significant improvements in wind speed simulation across all analyzed locations. At the Feliz Deserto station, the correlation increased from 0.56 (WRF) to 0.87 (WRF+LSTM), with a bias reduction from 0.50 m/s to –0.15 m/s, and a decrease in RMSE from 1.59 m/s to 0.72 m/s. Additionally, the normalized RMSE (nRMSE) dropped from 24% to 11%. Similar results were observed at the Girau do Ponciano and Água Branca stations, with correlation increases from 0.62 to 0.85 and from 0.54 to 0.85, respectively. At these stations, RMSE decreased from 2.69 m/s to 1.02 m/s, and from 2.02 m/s to 1.01 m/s, with notable reductions in nRMSE (from 31% to 12%, and from 25% to 12%). The WRF+LSTM approach significantly enhances wind speed simulation compared to the standalone WRF model. This combination improved the capture of seasonal variations, especially during periods of higher wind intensity. Furthermore, the model showed greater accuracy in representing the influence of sea and land breeze circulations, which significantly affect wind patterns, as well as the effects of complex terrain on atmospheric dynamics. The results indicate that the hybrid approach is promising for optimizing wind power forecasting, improving the planning and operation of wind farms. The study suggests that combining atmospheric models with neural networks can contribute to the expansion of renewable energy in Brazil, making power generation more efficient and predictable.

Keywords: Artificial neural networks; atmospheric modeling; LSTM; WRF; refinement.

LISTA DE FIGURAS

Figura 1 Mapa de Alagoas com a localização das estações anemométricas destacadas. 21

Figura 2 Evolução média da velocidade do vento a 100m ao longo do dia para as localidades de Feliz Deserto (a), Girau do Ponciano (b) e Água Branca (c). 27

Figura 3: Distribuição sazonal da potência eólica média nas localidades de Feliz Deserto (a), Girau do Ponciano (b) e Água Branca (c). 28

LISTA DE TABELAS

Tabela 1 Percentual de consistência dos dados anemométricos utilizados. 22

Tabela 2 Opções físicas utilizadas nas simulações. 23

Tabela 3 Detalhamento dos hiperparâmetros para configuração do modelo LSTM. 25

Tabela 4 Métricas estatísticas de desempenho (coeficiente de correlação, viés, RMSE e nRMSE) na comparação entre as velocidades do vento observadas e estimadas pelos modelos WRF e WRF+LSTM, para as localidades de Feliz Deserto, Girau do Ponciano e Água Branca.....28

Tabela 5 Comparação dos métodos de correção da velocidade do vento do WRF em diferentes estudos, com métricas de desempenho incluindo RMSE, MAE e correlação. 28

LISTA DE ABREVIATURAS E SIGLAS

ADAM	*Adaptive Moment Estimation*
EMOS	*Ensemble Model Output Statistics*
EPE	Empresa de Pesquisa Energética
FNL	*Final Analysis*
GRU	*Gated Recurrent Unit*
GWEC	*Global Wind Energy Council*
IEA	*International Energy Agency*
IEC	*International Electrotechnical Commission*
LSTM	*Long Short-Term Memory*
MAE	Erro Médio Absoluto
MOS	*Model Output Statistics*
NCEP	*National Centers for Environmental Prediction*
NEB	Nordeste Brasileiro
NWP	Previsão Numérica Do Tempo
RNA	Redes Neurais Artificiais
RNNs	Redes Neurais Recorrentes
RMSE	Raiz Do Erro Quadrático Médio
TSM	Temperatura da Superfície do Mar
WRF	*Weather Research and Forecasting*

SUMÁRIO

1. INTRODUÇÃO 11
2. REVISÃO BIBLIOGRÁFICA 13
3. METODOLOGIA 17
3.1. Área de estudo e dados das estações meteorológicas utilizados 17
3.2. Configuração do modelo WRF 19
3.3. Extrapolação vertical do vento 20
3.4. Configurações do modelo de aprendizado de máquina 20
3.5. Estimativa da densidade de energia eólica 22
3.6. Análise estatística 22
4. RESULTADOS E DISCUSSÕES 23
5. CONCLUSÃO 29
6. REFERÊNCIAS 31

1. INTRODUÇÃO

A crescente escassez de combustíveis fósseis e os impactos ambientais, têm impulsionado a busca por fontes renováveis, sendo a energia eólica uma alternativa promissora devido à sua natureza limpa e sustentável (DRANKA & FERREIRA, 2020). No entanto, sua variabilidade e intermitência desafiam a estabilidade da rede elétrica, levando ao desperdício de energia quando não há integração eficiente (ROSA ET AL., 2020). A previsão precisa da velocidade do vento é essencial para mitigar esse problema e aumentar a participação da energia eólica no suprimento energético. Globalmente, essa fonte tem crescido rapidamente, impulsionada pela necessidade de reduzir emissões de gases poluentes. No Brasil, desde 2009, a energia eólica se consolidou como a quarta maior geradora da matriz elétrica, representando 13% da geração nacional em 2023, com destaque para a Região Nordeste (EPE, 2024). O sucesso dessa expansão deve-se à abundância do recurso, aprimoramento das análises e alta competitividade, fatores que continuam impulsionando o desenvolvimento do setor.

Os modelos de previsão de energia eólica podem ser classificados em três categorias principais: baseados em princípios físicos, baseados em medições e modelos híbridos (TSAI et al., 2023; WANG et al., 2021). O primeiro grupo se apoia em valores gerados por modelos de previsão numérica e considera fatores físicos como o relevo local, o design dos parques eólicos e a curva de potência para calcular as estimativas de produção de energia em áreas específicas (TUY et al., 2022). O segundo grupo utiliza técnicas estatísticas para identificar as relações entre diversas variáveis explicativas, incluindo dados de séries temporais de estações meteorológicas e informações coletadas em tempo real de parques eólicos (SASSER et al., 2022). Já o terceiro grupo busca integrar diferentes abordagens ou modelos, com o intuito de aprimorar o desempenho geral ao combinar os pontos fortes de cada estratégia (CHE et al., 2024; YANG et al., 2023).

Atualmente, diversos modelos atmosféricos são amplamente utilizados para a simulação e previsão de variáveis meteorológicas. O modelo WRF (Weather Research and Forecasting) destaca-se como uma ferramenta relevante devido à sua capacidade de simular condições atmosféricas em múltiplas escalas, sendo frequentemente empregado na pesquisa e avaliação da produção de energia eólica (SOUZA et al., 2022). No entanto, as simulações e previsões numéricas sempre apresentam erros devido à natureza imprevisível dos sistemas atmosféricos e às limitações nos modelos atmosféricos, que são afetados pela parametrização dos processos físicos e pela discretização das equações diferenciais (SAYEED et al., 2023). Apesar dos avanços recentes, como uma melhor compreensão da dinâmica climática e recursos

computacionais aprimorados, os modelos atuais ainda apresentam vieses que reduzem a precisão das simulações, tornando a superação dessas limitações um desafio contínuo (SCHULTZ et al., 2021).

Dentre as diversas técnicas adotadas em modelos de previsão de energia eólica baseados em medições, as técnicas de aprendizado de máquina estão atraindo muitos pesquisadores ao redor do mundo atualmente (ARAUJO et al., 2023; CHE et al., 2022; XIONG et al., 2023; YANG et al., 2023). As redes neurais artificiais são amplamente utilizadas devido à sua capacidade de predição, sendo compostas por camadas de entrada, ocultas e de saída. As camadas ocultas são essenciais para o aprendizado e generalização, mas sua arquitetura deve ser bem projetada para evitar problemas como overfitting (sobreajuste) ou underfitting (subajuste) (SILVA, 2008). As redes neurais convencionais lidam com dados estáticos, mas para sequências temporais, surgiram as redes neurais recorrentes, que incorporam memória, permitindo que a rede leve em consideração dados passados, tornando-as ideais para tarefas como análise de séries temporais. Alves et al. (2023) analisaram diversos modelos baseados em distribuições estatísticas, modelos autorregressivos, métodos convencionais de aprendizado de máquina não neurais, redes neurais clássicas e redes neurais de aprendizado profundo para a simulação dos padrões do vento. Entre eles, a LSTM (long short-term memory) apresentou o melhor desempenho, com a menor taxa de erro, indicando maior precisão nas simulações. No Brasil, onde a infraestrutura e os recursos para a instalação e manutenção de estações meteorológicas são limitados, a aplicação dessa técnica pode se tornar inviável. Isso ocorre devido à escassez de séries de dados completas ou à presença de lacunas consideráveis, o que torna a implementação desafiadora em várias regiões do país.

Os modelos híbridos, que combinam a simulação com técnicas de aprendizado de máquina, têm se destacado como uma abordagem promissora para a simulação de energia eólica. Enquanto os modelos atmosféricos utilizam equações físicas para simular variáveis atmosféricas, o aprendizado de máquina atua como uma correção de vieses intrínsecos aos modelos, ajustando as simulações por meio da identificação de padrões não lineares nos dados históricos. Técnicas avançadas de aprendizado de máquina profundo para correção dos vieses nas saídas do modelo WRF, treinadas com dados meteorológicos históricos e medições em solo, superaram o desempenho do WRF na Malásia Oriental e Ocidental (ADOMAKO et al., 2024). Donadio et al. (2021) propuseram modelos híbridos que combinam simulações numéricas com RNA para estimar a velocidade do vento em terrenos altamente complexos e, em seguida, converter os valores para energia utilizando uma curva de potência ajustada. Devido a intensivas otimizações de parâmetros e arquiteturas, a metodologia desenvolvida é capaz de

fornecer simulações com maior precisão, alcançando um MAE (Erro Médio Absoluto) de 8,76% e um RMSE (Raiz Do Erro Quadrático Médio) de 13,03%, sem a necessidade de abordagens físicas pesadas.

Entre os diversos modelos híbridos desenvolvidos, não é possível determinar qual é o melhor, uma vez que cada modelo é restrito às características do local, bem como variam em detrimento dos conjuntos de dados utilizados (WANG et al., 2021). Dessa forma, um modelo híbrido desenvolvido para um determinado local geralmente não apresenta o desempenho ideal quando aplicado a outras regiões.

Este trabalho tem como objetivo geral aprimorar as estimativas de velocidade do vento a 100 metros de altura fornecidas pelo modelo WRF, por meio de técnicas de pós-processamento baseadas em redes neurais recorrentes do tipo LSTM. O estudo é aplicado ao estado de Alagoas, com o intuito de aumentar a acurácia e a representatividade das simulações em relação aos dados observacionais, promovendo uma modelagem mais precisa do recurso eólico. Como objetivo específico, busca-se revelar o potencial eólico do estado de Alagoas por meio da aplicação do modelo híbrido WRF+LSTM, aprimorando a precisão das simulações para apoiar o planejamento e a expansão sustentável da energia eólica na região.

2. REVISÃO BIBLIOGRÁFICA

O setor energético tem enfrentado desafios diante do cenário das mudanças climáticas a fim de mitigar os impactos e diversificar a matriz energética. Com isso, a energia eólica é apresentada como uma solução promissora, revelando potencial no âmbito global (BARTHELMIE; PRYOR, 2021). Segundo o relatório global eólico referente ao ano de 2023 produzido pelo GWEC (Global Wind Energy Council), foi um ano que apresentou recorde com novas instalações adicionando 106 GW de energia eólica onshore e 10,8 GW de energia eólica offshore. No mesmo ano, o Brasil contabilizou 1027 parques eólicos com 30,45 GW de potência, um crescimento de 18,79% em comparação com o ano anterior, quando sua capacidade instalada era de 25,63 GW. Dessa forma, tornou-se o terceiro país que mais instalou parques eólicos no mundo, tendo apenas a China e Estados Unidos à sua frente (ABEEOLICA, 2024). A Empresa de Pesquisa Energética (EPE), aponta que a região nordeste concentra aproximadamente 90% da capacidade eólica, devido ao favorecimento de ventos na região costeira e semiárida com topografia complexa, mais especificamente estados de Alagoas, Bahia, Paraíba e Pernambuco (AMARANTE et al, 2001).

A região costeira do NEB é destacada devido à persistência e intensidade dos ventos alísios (BRITO, 2018). Em menor escala, um tipo de circulação local são as brisas - os principais tipos de brisas são os que acontecem entre continente-oceano e vale-montanha. As brisas terrestres se dão de forma análoga as brisas marítimas, diferindo apenas no sentido da circulação: as marítimas se originam da expansão das camadas de ar nas camadas superficiais da terra, uma vez que a radiação solar é absorvida e reemitida em menor tempo no continente que no mar. Expansão essa que produz fluxo de ar aquecido nos níveis superiores da terra para o mar chamado fluxo de retorno. A manutenção deste fluxo sobre o mar indica um gradiente de pressão que cria um fluxo de ar nos níveis inferiores do mar para o continente, formando a brisa marítima, que contribui fortemente para intensificação e variação da direção dos ventos alísios. Já para a origem da brisa terrestre, por a terra resfriar em menos tempo que o mar, o ar resfriado do continente migra para o mar em níveis inferiores, aquece, ascende e retorna (fluxo de retorno) para o continente (ATKINSON, 1981; SILVA, 2015).

As brisas que ocorrem em regiões montanhosas são devidas às variações térmicas induzidas pela forma e cobertura dessas superfícies: as massas de ar estagnadas nas superfícies laterais das montanhas são aquecidas, com isso se tornam mais leves e avançam em direção ao topo, processo conhecido como ventos anabáticos. Acima do topo das montanhas, estes ventos ascendentes passam pelo processo de inversão térmica e são forçados para um fluxo de retorno. Durante a noite, a circulação reversa acontece devido a rápida liberação de calor do topo das montanhas, resfriando o ar adjacente nas laterais, obrigando um deslocamento descendente para o centro do vale. Estes ventos são chamados de ventos catabáticos e o fluxo de retorno desta circulação é chamado de vento antimontanha.

A Temperatura da Superfície do Mar (TSM) do Pacífico equatorial também está associada a mudanças nos padrões de circulação atmosférica sobre o Nordeste (ALEXANDER; SCOTT, 2002). Eventos como El Niño, caracterizado pelo aquecimento das águas da superfície do Oceano Pacífico equatorial e La Niña, quando ocorre o oposto, atuam de maneira que pode intensificar ou enfraquecer os ventos na região (OLIVEIRA; COSTA, 2011). De acordo com os estudos de Da Silva (2007), eventos como El Niño influencia o vento na região de tabuleiro costeiro de Alagoas, provocando uma aceleração no fluxo e mudança na direção. Em fases de transição de La Niña para El Niño os valores da velocidade do vento também são mais altos e atuam intensificando ou enfraquecendo os ventos sobre a região nordestina (FIGUEIREDO, 2009).

Além dos fatores meteorológicos supracitados, deve-se levar em consideração os aspectos como topografia e rugosidade. As características topográficas de uma área influenciam

o comportamento do vento ocasionando tanto a aceleração quanto a redução da sua velocidade. Além disso, a rugosidade do terreno, elementos como árvores, arbustos, vegetação rasteira e pequenas construções sobre a superfície do solo causam resistência na superfície terrestre à passagem do escoamento e podem originar mudança da direção e pequenas turbulências na superfície (SILVA, 2011).

No contexto de produção de energia eólica é de suma importância ter as informações de condições meteorológicas, para que assim seja permitido avaliar e quantificar a produção. No entanto, um dos principais desafios enfrentados nesse processo é a escassez de dados precisos e uma base com série temporal longa. Essa limitação compromete diretamente as estimativas de produção eólica. Tal lacuna pode ser contornada com o emprego da modelagem numérica atmosférica, uma excelente alternativa para o setor energético tornando possível obter estimativas mais precisas sobre os padrões de vento, considerando tanto áreas com maior nível de detalhe quanto diferentes períodos de tempo — sejam séries mais curtas para aplicações imediatas ou mais longas para análises históricas. Esses dados são essenciais para entender o comportamento do vento em determinada região e, assim, apoiar decisões mais seguras e estratégicas sobre onde investir e instalar novos parques eólicos (MARTINS, GUARNIERI E PEREIRA, 2008). Nas últimas décadas, os modelos de previsão numérica do tempo (NWP) vêm alcançando avanços significativos, impulsionados tanto pela evolução do conhecimento sobre os processos atmosféricos quanto pelo aumento da capacidade computacional. Apesar disso, esses modelos ainda enfrentam limitações, como a presença de vieses que comprometem a precisão das simulações. Por isso, aperfeiçoar esses resultados continua sendo um desafio constante (SCHULTZ et al., 2021). Nesse cenário, o uso de técnicas de pós-processamento — como a correção de viés — tem se mostrado essencial para refinar as simulações e previsões e torná-las mais confiáveis e úteis na prática.

Os modelos numéricos de previsão do tempo (NWP) têm sido amplamente utilizados para estimar o potencial eólico em diferentes escalas temporais e espaciais (BYRKJEDAL E BERGE, 2008; CARVALHO et al, 2013). No entanto, apesar dos avanços recentes, esses modelos ainda enfrentam limitações importantes relacionadas à resolução espacial, representação física e, sobretudo, à presença de viés sistemático nas simulações (SCHULTZ et al., 2021). Esse viés pode comprometer significativamente a confiabilidade das simulações meteorológicas utilizadas em aplicações sensíveis, como a estimativa de produção de energia eólica. Nesse contexto, técnicas de pós-processamento, como correção de bias, tornaram-se ferramentas indispensáveis para refinar os dados simulados e aproximá-los das observações reais.

Métodos clássicos como *Quantile Mapping*, ajuste linear, *Model Output Statistics* (MOS) e *Ensemble Model Output Statistics* (EMOS) têm sido amplamente utilizados, cada um com seus pontos fortes e limitações (ZHANG, CUI & CHEN, 2021). A aplicação dessas técnicas em dados de vento é particularmente relevante, já que erros em velocidade e direção do vento impactam diretamente a simulação da geração eólica, o planejamento de parques e a avaliação de viabilidade econômica (BENOIT et al., 2011). A eficácia desses métodos, porém, varia conforme o relevo, cobertura do solo e regime climático, o que exige atenção especial em regiões com grande variabilidade espacial, como é o caso do Nordeste brasileiro.

Paralelamente aos métodos estatísticos, o avanço de técnicas de aprendizado de máquina, especialmente das Redes Neurais Recorrentes (RNNs) e suas variantes modernas como a Long Short-Term Memory (LSTM), tem impulsionado novas abordagens para simulação e correção de viés. Proposta por Hochreiter & Schmidhuber (1997), a LSTM é projetada para lidar com dependências de longo prazo em séries temporais, sendo especialmente adequada para modelar padrões meteorológicos sazonais e não lineares (SIWEK et al., 2021).

Na prática, a LSTM tem sido aplicada com sucesso na simulação de variáveis meteorológicas como vento, temperatura e radiação solar, inclusive em regiões litorâneas e semiáridas, onde fatores como brisas e efeitos locais introduzem alta variabilidade (BASTOS et al., 2020; SILVA et al., 2024; MOTA et al, 2025). Além disso, seu uso vem se expandindo para correção de viés dinâmica, onde o modelo é treinado para aprender os padrões sistemáticos de erro dos modelos NWP e gerar saídas corrigidas com base em dados observacionais ou de reanálise (SHI et al., 2022).

Estudos recentes, como os de Qureshi et al. (2020) e Zhang et al. (2023), demonstram que arquiteturas híbridas — que combinam LSTM com métodos estatísticos ou outras redes, como CNN-LSTM e Bi-LSTM — superam métodos convencionais em métricas como RMSE e correlação com observações, especialmente na simulação do vento e potencial eólico.

Contudo, a aplicação de LSTM exige atenção à qualidade e quantidade de dados disponíveis, bem como à escolha adequada de hiperparâmetros e arquitetura. Além disso, embora a correção de viés melhore a acurácia dos modelos (THEMEL, GOBIET & LEUPRECHT, 2011), há um debate sobre até que ponto essas correções podem mascarar deficiências físicas dos modelos, especialmente em simulações de longo prazo (EHRET et al., 2012).

Dessa forma, a integração entre modelagem física e inteligência artificial, por meio de técnicas como LSTM aplicadas à correção de viés, representa uma fronteira promissora na simulação de vento e no planejamento da geração eólica. A escolha adequada da abordagem —

estatística ou baseada em IA (Inteligência Artificial) — deve considerar o contexto local, os dados disponíveis e o objetivo final da aplicação (BROWELL, MCMILLAN & INFIELD, 2014).

3. METODOLOGIA

3.1. Área de estudo e dados das estações meteorológicas utilizados

O relevo de Alagoas é predominantemente plano, com a maior parte do estado situando-se abaixo de 300 metros de altitude, enquanto apenas uma pequena porção ultrapassa os 600 metros, conforme ilustrado na Figura 1. A mesorregião do leste alagoano possui aproximadamente 230 km de litoral, caracterizado por altitudes baixas e topos planos que se estendem até 100 metros, avançando cerca de 25 km para o interior. No Norte, na região do agreste alagoano, encontra-se a encosta meridional do Planalto da Borborema, cuja elevação ultrapassa os 600 metros. Já no interior do estado, destacam-se algumas serras, principalmente no município de Água Branca, a oeste, onde as altitudes variam entre 500 e 800 metros (ELETROBRÁS, 2008).

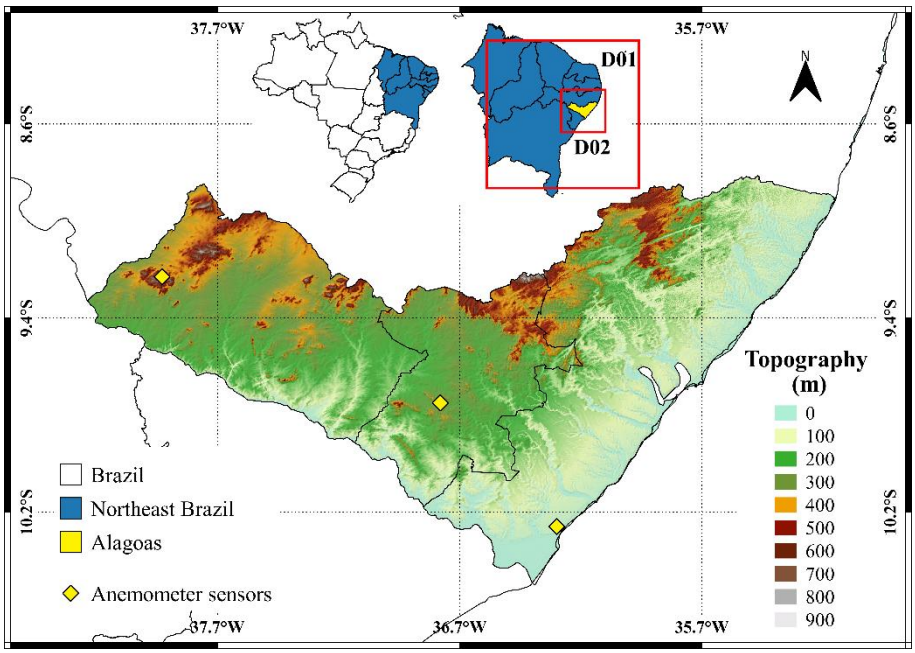


Figura 1: Mapa de Alagoas com a localização das estações anemométricas destacadas
Fonte: Autor, 2025

Os dados observados adotados para esse estudo foram obtidos das torres anemométricas do projeto do convênio (ECV – 156/2005) entre as centrais elétricas brasileiras -

ELETROBRAS, Instituto de Tecnologia para o Desenvolvimento – LACTEC (Paraná) e Universidade Federal de Alagoas – UFAL desenvolvido pelo projeto "Atlas Eólico e Disseminação da Tecnologia Eólica no Estado de Alagoas" (ELETROBRÁS, 2008). Das estações anemométricas instaladas por esse projeto, foi escolhida uma de cada mesorregião (Figura 1): Água Branca com altura da torre de 50m e sensores anemométricos a 30 e 50m para o sertão, Girau do Ponciano com torre de 100m e altura dos sensores a 30 e 50m representando a mesorregião do agreste, e Feliz Deserto com torre de 100m e sensores a 30, 70 e 100m, representando o leste alagoano. Os dados utilizados foram coletados entre janeiro e dezembro de 2008.

As torres e seus instrumentos foram instalados em conformidade com os padrões de qualidade e segurança estabelecidos pelas agências reguladoras: IEA (International Energy Agency) e IEC (International Electrotechnical Commission). Os dados medidos foram registrados no datalogger com médias a cada 10 minutos e, posteriormente, submetidos a um controle de qualidade. Em seguida, foi realizada uma análise de consistência dos dados coletados nas estações, cujos percentuais estão apresentados na Tabela 1. A consistência dos dados é fundamental para o bom desempenho de redes neurais recorrentes. Dados inconsistentes podem comprometer o treinamento e reduzir a capacidade de generalização do modelo. Além disso, a escassez de dados pode causar problemas como overfitting, underfitting, generalização inadequada, sensibilidade a ruídos e dificuldade em capturar padrões sazonais ou de longo prazo. Portanto, garantir um conjunto de dados robusto e confiável é fundamental para obter simulações precisas e estáveis.

Tabela 1: Percentual de consistência dos dados anemométricos utilizados.

Cidade/Mês	**01**	**02**	**03**	**04**	**05**	**06**	**07**	**08**	**09**	**10**	**11**	**12**
Água Branca	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
Girau do Ponciano	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
Feliz Deserto	74%	57%	100%	65%	32%	35%	100%	100%	100%	100%	100%	100%

Fonte: Autor, 2025

3.2. Configuração do modelo WRF

O modelo atmosférico WRF (Weather Research and Forecasting) desenvolvido no National Center for Atmospheric Research (Skamarock et al., 2005, 2008), versão 4.4.2 foi utilizado neste estudo de modo a analisar o estado de Alagoas. Foram utilizados dados do NCEP (National Centers for Environmental Prediction) FNL (Final Analysis) para inicialização do WRF, com resolução espacial de 1°, resolução temporal de 6 horas e proporção de decaimento da resolução espacial 4:1. Os domínios foram configurados com dimensões horizontais de 20 km (81 × 81 pontos de grade) para o domínio 1 e 5 km (81 × 81 pontos de grade) para o domínio 2 (Figura 1). As saídas do domínio 2 foram armazenadas com frequência horária, e os principais parâmetros extraídos do modelo incluem as componentes do vento meridional (v10) e zonal (u10) a 10 metros, a velocidade de fricção e a altura da camada limite planetária. Essas variáveis também serão utilizadas como dados de entrada para o treinamento e validação da LSTM. As simulações foram realizadas com resolução temporal de 24 horas ao longo de um período de um ano, de janeiro a dezembro de 2008, começando dia 18h do dia anterior, sendo descartada as 6h e sendo avaliada as 24h com simulações diárias. A física do modelo utiliza parametrização de convecção de cumulus, esquema de microfísica das nuvens, transferência radiativa de onda longa e curta, turbulência e difusão, Camada Limite Planetária, camada limite superficial e modelo de superfície do solo para as duas grades. (Tabela 2).

Tabela 2: Opções físicas utilizadas nas simulações

Parametrizações	**Opções físicas**
Camada limite planetária	ACM2 (Pleim, 2007)
Camada limite superficial	NOAH (Niu et al, 2011)
Cumulus	GRELL-3D (Grell e Freitas, 2014)
Microfísica	GODDARD (Tao et al., 2016)

Radiação de onda curta	RRTMG (Iacono et al, 2008)
Radiação de onda longa	RRTMG (Iacono et al, 2008)

Fonte: Autor, 2025

3.3. Extrapolação vertical do vento

A variável velocidade do vento é formada pelas componentes de vento meridional (v10) e zonal (u10) a 10 metros e, posteriormente, extrapolada para a altura de 100m utilizando a lei da potência (Equação (1). Ressalta-se que as medições para a cidade de Girau do Ponciano possuem dados de velocidade do vento medidos a 50 metros. Dessa forma, aplicou-se também a técnica de extrapolação vertical do vento para ajustar os valores a 100 metros, garantindo comparações consistentes entre as localidades. Essa técnica é amplamente utilizada e permite a obtenção de estimativas precisas para a velocidade do vento em diferentes alturas (CAO et al., 2023; JUNG & SCHINDLER, 2021; SASSER et al., 2022). Para estimar a velocidade do vento em uma altura superior, relaciona-se a velocidade do vento em uma altura desejada (z) com a velocidade do vento medida em uma altura de referência (z1), considerando um expoente empírico (α), que reflete as características da rugosidade da superfície. A equação é dada por:

$$\mathrm{V} = \mathrm{V_{ref}} \cdot \left(\frac{z}{z_1}\right)^{\alpha} \quad (1)$$

onde, adotou-se α = 0,12. Para fins de energia eólica, tem sido comum usar a lei de potência com um α fixo, independente do tempo e do espaço, para cada tipo geográfico. Em condições offshore normais, α = 0,12 tem sido comumente usados (Det Norske Veritas, 2010).

3.4. Configurações do modelo de aprendizado de máquina

A metodologia empregada para a construção e treinamento do modelo de simulação descrito segue uma abordagem estruturada para trabalhar com dados temporais, especificamente séries temporais de variáveis meteorológicas. A primeira etapa envolve a seleção das variáveis de entrada e do alvo observado, fundamentais para o treinamento do modelo. Neste caso, as variáveis de saída do WRF, como a velocidade do vento a 10m e 100m,

a velocidade de fricção do vento e a altura camada limite atmosférica, são selecionadas como características de entrada, enquanto a medição da velocidade do vento a 100m é o alvo, ou seja, a variável que será simulada. A escolha dessas variáveis é estratégica, pois elas estão diretamente relacionadas aos fatores que influenciam o comportamento da velocidade do vento, o que torna o modelo mais adequado para realizar a simulação.

O modelo de rede neural é construído pelo framework de aprendizado profundo PyTorch e a biblioteca Keras (KERAS,2024), e sua arquitetura é composta por três camadas principais. A primeira camada é do tipo LSTM, um modelo projetado para aprender dependências de longo prazo nas séries temporais (HOCHREITER; SCHMIDHUBER, 1997), com 50 unidades de memória. Em seguida, adiciona-se uma camada GRU (Gated Recurrent Unit), uma variante mais simples da LSTM, configurada com 100 unidades. Essa arquitetura foi proposta por Cho et al. (2014) como uma alternativa computacionalmente mais eficiente, mantendo desempenho competitivo em tarefas de modelagem sequencial. Essas camadas são responsáveis por aprender as relações temporais dos dados, processando as informações de forma eficiente e passando as saídas de uma camada para a próxima, conforme necessário para o aprendizado. A última camada do modelo é uma camada densa, com uma única unidade, que gerará a previsão do modelo para o próximo passo de tempo. A compilação do modelo é realizada com o otimizador Adam (*Adaptive Moment Estimation*), que é vantajoso por precisar apenas dos gradientes de primeira ordem e exigir pouca memória para seu funcionamento (KINGMA; BA, 2014). A taxa de aprendizado é configurada em 0.001, um valor comum para esse tipo de modelo. O erro do modelo é avaliado utilizando a função de perda MSE (mean squared error), que é adequada para problemas de regressão, pois penaliza grandes erros de previsão (GERON, 2019).

O treinamento é realizado em 100 épocas, com Batch size (tamanho do lote) de 32, o que significa que os pesos são atualizados após processar 32 amostras. O desempenho do modelo é monitorado no conjunto de teste para evitar overfitting. Para avaliação, 70% dos dados de velocidade do vento são usados para treinar o modelo, enquanto os 30% restantes ajustam o modelo. Os dados foram estruturados em uma janela de 30 passos de tempo para que a rede LSTM possa aprender padrões temporais. A Tabela 3 apresenta os hiperparâmetros utilizados no treinamento da rede.

Tabela 3: Detalhamento dos hiperparâmetros para configuração do modelo LSTM.

Modelo	***Epochs***	**Células na camada de entrada LSTM**	**Células na camada de entrada GRU**	**Células na camada de saída DENSE**	**Optimizer/ *learning rate***	***Bach size***	***Loss function***
LSTM	100	50	100	1	Adam/0.001	32	MSE

Fonte: Autor, 2025

3.5. Estimativa da densidade de energia eólica

A intensidade do vento disponível em uma determinada região é representada pela densidade de potência disponível por unidade de área (W/m²). Esse parâmetro é essencial para estimar o potencial energético do vento e quantificar a energia eólica em diferentes velocidades dentro de um local específico. Além disso, a densidade de potência é empregada na análise de desempenho de aerogeradores e na escolha da turbina mais adequada para um determinado ponto (CRESESB, 2001). A geração de energia eólica está diretamente relacionada ao cubo da velocidade do vento. Dessa forma, a densidade de potência, considerando uma série temporal da velocidade do vento em um local, pode ser determinada por meio da seguinte equação:

$$P = \frac{1}{2} \cdot \rho \cdot V^3 \qquad (2)$$

onde, V é a velocidade do vento (m/s) e ρ é a densidade do ar (kg/m^3). Para simplificação, considera-se ρ = 1,225 kg/m^3.

3.6. Análise estatística

As métricas estatísticas desempenham um papel fundamental na avaliação da precisão das simulações da velocidade do vento, permitindo quantificar os desvios entre os valores simulados e observados (Araujo et al., 2023; Stetco et al., 2019). O coeficiente de correlação de Pearson (r) é uma métrica essencial para medir a relação linear entre os valores previstos e

os observados, indicando a qualidade do ajuste do modelo. O erro médio de viés (MBE), por sua vez, avalia a tendência sistemática do modelo, indicando se as previsões estão superestimando ou subestimando os valores reais. Já a raiz do erro quadrático médio (RMSE) mede a magnitude média dos erros, sendo mais sensível a grandes discrepâncias, o que ajuda a identificar e corrigir previsões extremas inadequadas. Além disso, o RMSE normalizado (nRMSE) é amplamente utilizado em grandes conjuntos de dados, pois permite comparar a precisão das previsões em diferentes escalas, facilitando a interpretação dos erros relativos ao valor médio da variável. Essas métricas, quando analisadas em conjunto, fornecem uma visão abrangente do desempenho dos modelos, contribuindo para o aprimoramento da precisão das previsões de vento. As equações dessas métricas são as seguintes:

$$r = \frac{\sum_{i=1}^{n} \quad [(x_i - \underline{x_i})\left(y - \underline{y_i}\right)]}{\sqrt{\sum_{i=1}^{n} \quad \left(x_i - \underline{x_i}\right)^2} \cdot \sqrt{\sum_{i=1}^{n} \quad \left(y_i - \underline{y_i}\right)^2}} \tag{3}$$

$$viés = \frac{1}{N}\sum_{i=1}^{n} \quad (x_i - y_i) \tag{4}$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{n} \quad (x_i - y_i)^2} \tag{5}$$

$$nRMSE = \frac{RMSE}{\underline{y}} \cdot 100\% \tag{6}$$

onde x é a grandeza da velocidade do vento estimada, y a grandeza observada e $\underline{x}$ e $\underline{y}$ indicam as médias dessas grandezas.

4. RESULTADOS E DISCUSSÕES

A comparação das métricas estatísticas entre os modelos WRF e WRF+LSTM para as localidades de Feliz Deserto, Girau do Ponciano e Água Branca (Tabela 4) evidencia melhorias significativas no desempenho do modelo híbrido em relação ao modelo atmosférico isolado. Ao analisar o coeficiente de correlação, observa-se que o WRF+LSTM supera consistentemente o WRF em todas as localidades, demonstrando uma capacidade aprimorada de reproduzir a variabilidade temporal da velocidade do vento. Em Feliz Deserto, a correlação aumenta de 0,56

(WRF) para 0,87 (WRF+LSTM); em Girau do Ponciano, de 0,62 para 0,86; e em Água Branca, de 0,54 para 0,85, evidenciando um ajuste mais preciso da rede neural aos padrões de vento locais. O viés médio da simulação também destaca vantagens do WRF+LSTM sobre o WRF. Enquanto o WRF apresenta valores de viés mais acentuados e, por vezes, negativos – como em Girau do Ponciano (-2,09 m/s) e Água Branca (-0,52 m/s) – o WRF+LSTM corrige essas tendências, reduzindo o viés para valores próximos de zero: -0,15 m/s em Feliz Deserto, 0,01 m/s em Girau do Ponciano e 0,13 m/s em Água Branca. Esses resultados indicam que o modelo híbrido é menos tendencioso e fornece simulações mais equilibradas. Quanto ao erro quadrático médio (RMSE), a redução promovida pelo WRF+LSTM é expressiva: em Feliz Deserto, o RMSE diminui de 1,75 m/s para 0,70 m/s (redução de aproximadamente 55%); em Girau do Ponciano, de 2,53 m/s para 0,98 m/s (redução de cerca de 62%); e em Água Branca, de 2,02 m/s para 1,05 m/s (redução de 50%). O erro normalizado (nRMSE) reforça essa tendência de melhoria relativa: os valores caem de 26% para 11% em Feliz Deserto, de 30% para 11% em Girau do Ponciano e de 25% para 13% em Água Branca. Esses resultados demonstram que a incorporação da rede neural LSTM ao pós-processamento das saídas do WRF contribui significativamente para a melhora da acurácia e da representatividade das estimativas de velocidade do vento nas três localidades analisadas.

Tabela 4: Métricas estatísticas de desempenho (coeficiente de correlação, viés, RMSE e nRMSE) na comparação entre as velocidades do vento observadas e estimadas pelos modelos WRF e WRF+LSTM, para as localidades de Feliz Deserto, Girau do Ponciano e Água Branca.

Métricas	Feliz Deserto		Girau do Ponciano		Água Branca	
	WRF	WRF+LSTM	WRF	WRF+LSTM	WRF	WRF+LSTM
Correlação	0,56	**0,87**	0,62	**0,86**	0,54	**0,85**
Viés (m/s)	0,83	**-0,15**	-2,09	**0,01**	-0,52	**0,13**
RMSE (m/s)	1,75	**0,70**	2,53	**0,98**	2,02	**1,05**
nRMSE (%)	26	**11**	30	**11**	25	**13**

Fonte: Autor, 2025

De forma semelhante aos resultados pesquisados na literatura (Tabela 5), nota-se que os RMSE obtidos pelo modelo WRF+LSTM no presente estudo (variando entre 0,70 m/s e 1,05 m/s) revelou-se eficaz, demonstrando que a correção de bias aplicada é capaz de aprimorar significativamente a precisão das simulações da velocidade do vento. Xu et al. (2021)

reportaram um RMSE de 1,99 m/s para o modelo WRF+LSTM, enquanto Adomako et al. (2024) obtiveram um RMSE de 1,01 m/s. Quando comparado a outros métodos de correção, como redes neurais artificiais (ANN), máquinas de vetor de suporte (SVM), florestas aleatórias (RF) e retropropagação (BP), os valores do presente estudo indicam que o modelo WRF+LSTM pode ser mais eficaz na correção da velocidade do vento, superando abordagens amplamente utilizadas. Kara et al. (2023) relataram um RMSE de 0,96 m/s para o WRF+ANN, enquanto Zhang et al. (2024) apresentaram valores entre 1,78 m/s e 2,06 m/s para modelos baseados em WRF+RF, WRF+SVM e WRF+BP. Em termos de correlação, os valores obtidos (acima de 0,80) são superiores aos reportados na literatura. Zhang et al. (2024) registraram correlações entre 0,49 e 0,59, e Adomako et al. (2024) obteve 0,60 para WRF+LSTM. Isso demonstra que a abordagem do modelo híbrido no presente estudo resultou em um melhor ajuste entre os dados simulados e observados, tornando-se uma alternativa viável para melhorar a precisão da velocidade do vento.

Tabela 5: Comparação dos métodos de correção da velocidade do vento do WRF em diferentes estudos, com métricas de desempenho incluindo RMSE, MAE e correlação.

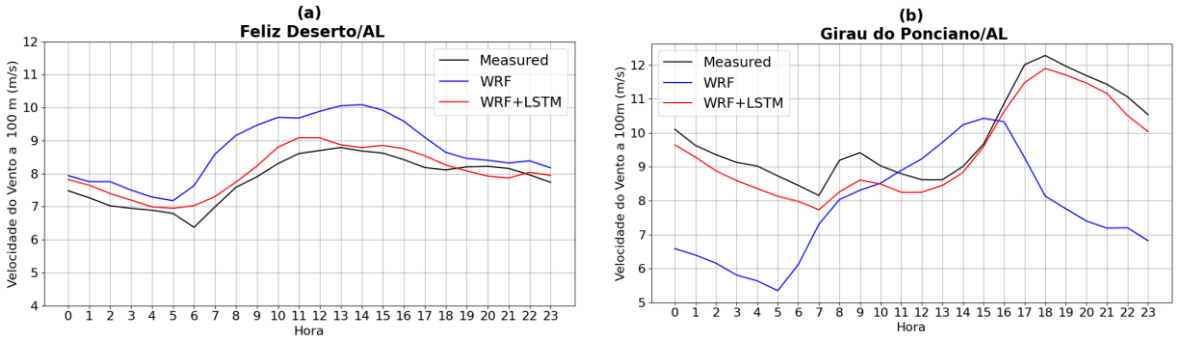
Referência	**Métodos**	**RMSE**	**MAE**	**Correlação**
Xu et al. (2021)	WRF+LSTM	1,99	1,66	-
Kara et al. (2023)	WRF+ANN	0,96	0,04	0,56
Zhang et al. (2024)	WRF + RF	1,78	−0,09	0,59
	WRF + SVM	1,84	−0,34	0,57
	WRF + BP	2,06	−0,04	0,49
Adomako et al. (2024)	WRF+LSTM	1,01	0,74	0,60

Fonte: Autor, 2025

Dessa forma, os resultados indicam que a combinação do WRF+LSTM abre possibilidades para corrigir limitações do modelo atmosférico, especialmente em regiões de relevo complexo, como Girau do Ponciano e Água Branca. Essas áreas são caracterizadas por terrenos acidentados, com serras e vales que influenciam significativamente a dinâmica do vento. Nessas localidades, os efeitos de interação entre a topografia e a atmosfera tornam a modelagem mais complexa, tornando essencial o uso de abordagens híbridas que combinem

simulação numérica com aprendizado de máquina para capturar melhor essas variações espaciais e dinâmicas (Che et al., 2022).

A análise do ciclo diurno da potência eólica revela comportamentos distintos entre as localidades estudadas. As condições meteorológicas dessas regiões são fortemente influenciadas pelo regime de ventos alísios e pela topografia local. Em Feliz Deserto, observa-se uma variação bem marcada ao longo do dia, com aumento da potência eólica durante o período diurno, o que está associado à intensificação da radiação solar e ao desenvolvimento da circulação de brisas marítima e terrestre, típicas de regiões litorâneas. Já em Girau do Ponciano e Água Branca, ambas situadas em áreas de relevo acidentado, a dinâmica do vento é mais influenciada por sistemas locais como a brisa vale-montanha e a canalização dos ventos por picos de elevação próximos (ELETROBRÁS, 2008). Nessas localidades, os máximos de potência eólica tendem a ocorrer nos períodos da madrugada e início da manhã, momentos em que o resfriamento do ar nas regiões mais elevadas favorece a intensificação do escoamento descendente. Em Água Branca ressalta-se também a atuação de sistemas semelhantes ao vento "aracati", que contribuem para o aumento da velocidade do vento durante a madrugada e início da manhã.



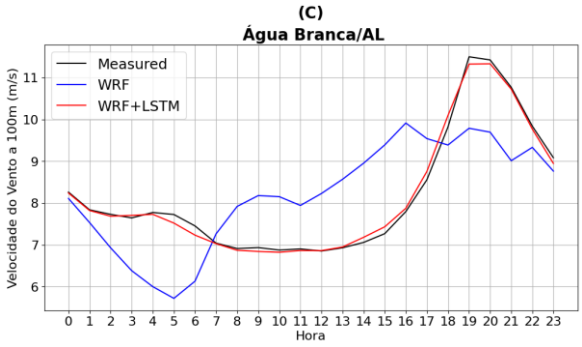


Figura 2: Evolução média da velocidade do vento a 100m ao longo do dia para as localidades de Feliz Deserto (a), Girau do Ponciano (b) e Água Branca (c).

Fonte: Autor, 2025

Quanto à densidade de potência eólica nos meses selecionados para teste, observa-se que, em Feliz Deserto, a variação ao longo dos meses é moderada, sugerindo certa regularidade na disponibilidade de vento. Esse comportamento pode estar relacionado à atuação consistente das brisas litorâneas, características da região. Em contraste, os municípios de Girau do Ponciano e Água Branca apresentam maior variabilidade nos valores de densidade de potência, com destaque para o aumento nos meses mais secos (como observado em novembro). Essa flutuação ao longo do tempo reforça o potencial da geração eólica como recurso complementar ao sistema hidrelétrico, sobretudo no Nordeste brasileiro, onde há redução da disponibilidade hídrica durante os períodos de estiagem (DE JONG et al., 2013). A maior disponibilidade de vento em Girau do Ponciano e Água Branca nesses períodos pode funcionar como um importante mecanismo de segurança energética, atenuando os impactos da escassez de água nos reservatórios e diminuindo a necessidade de acionamento de usinas térmicas, que são mais custosas e poluentes. Assim, a inserção estratégica da energia eólica nessas localidades contribui não apenas para diversificar a matriz elétrica, mas também para torná-la mais resiliente frente às variações climáticas.

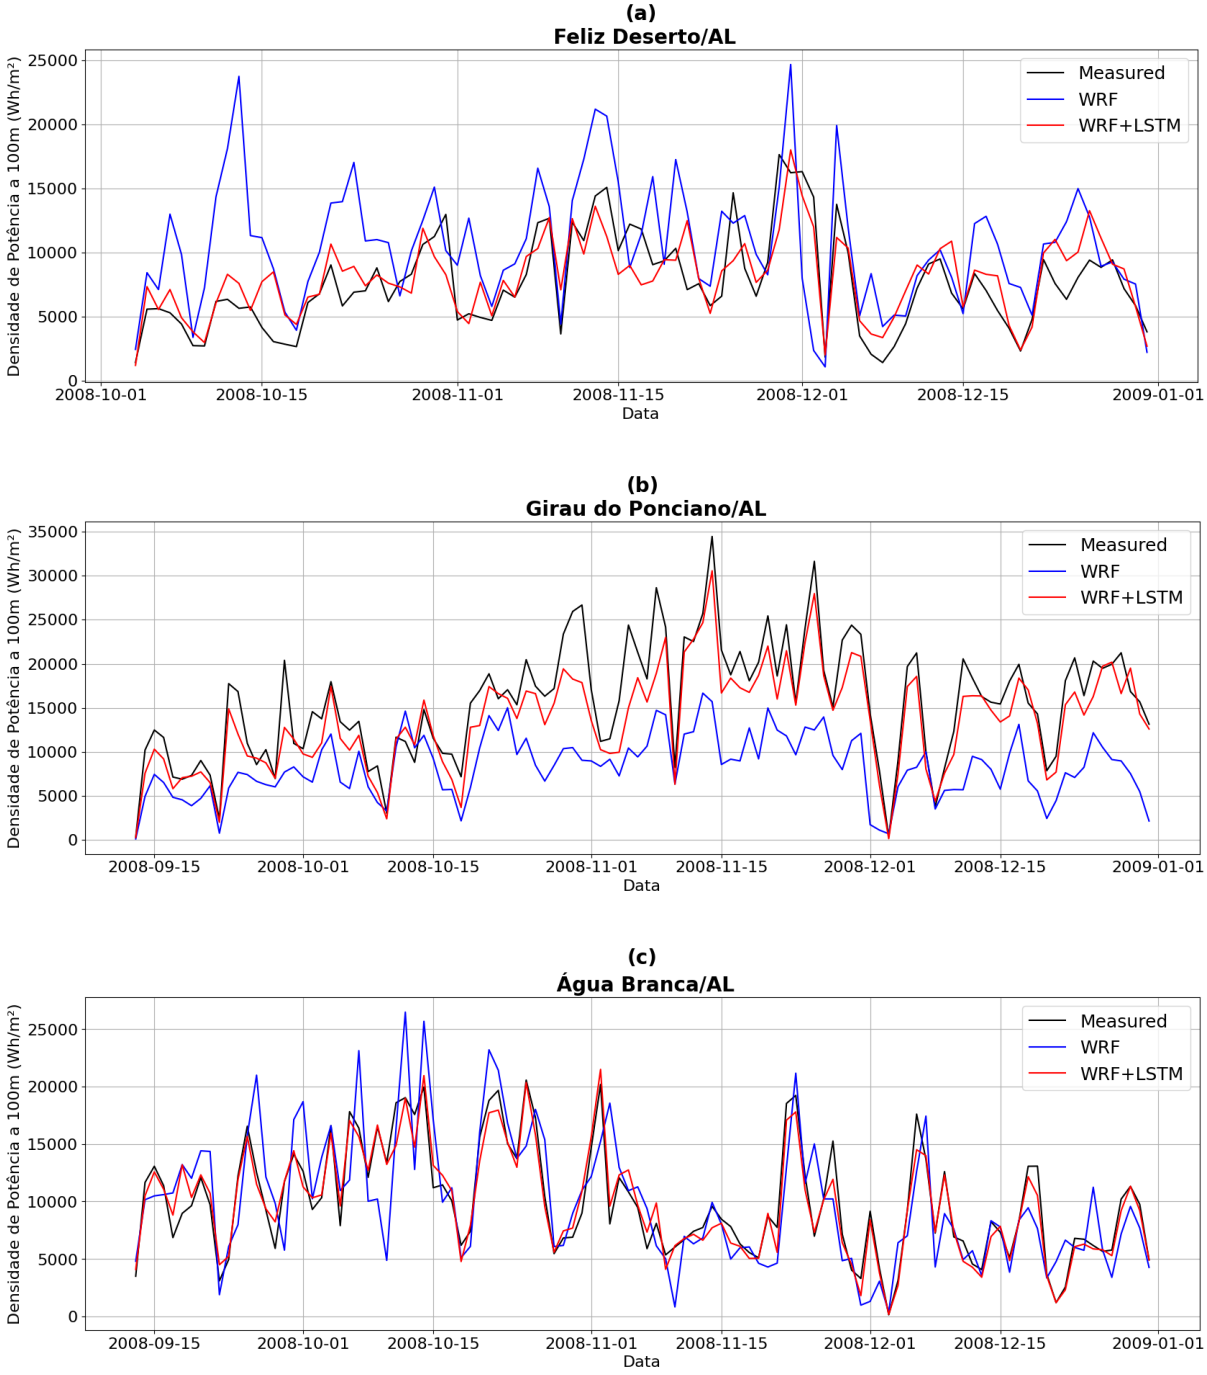


Figura 3: Distribuição da potência eólica para os meses separados para teste nas localidades de Feliz Deserto (a), Girau do Ponciano (b) e Água Branca (c).

Fonte: Autor, 2025

5. CONCLUSÃO

O presente estudo demonstrou a eficácia do uso de redes neurais para o refinamento de dados simulados do modelo atmosférico WRF, aprimorando as simulações da velocidade do vento em diferentes regiões do estado de Alagoas. Os resultados revelaram melhorias expressivas nas métricas estatísticas ao comparar o desempenho do modelo híbrido WRF+LSTM com o modelo WRF isolado.

O coeficiente de correlação (R) aumentou significativamente em todas as localidades analisadas, indicando um melhor ajuste temporal do modelo híbrido aos padrões observados: em Feliz Deserto, a correlação subiu de 0,56 para 0,87; em Girau do Ponciano, de 0,62 para 0,86; e em Água Branca, de 0,54 para 0,85. Esses aumentos demonstram a maior capacidade do WRF+LSTM de representar a variabilidade local do vento.

O viés médio das simulações também apresentou redução substancial, evidenciando menor tendência sistemática de erro no modelo híbrido. Enquanto o WRF apresentou viés de -2,09 m/s em Girau do Ponciano e -0,52 m/s em Água Branca, o WRF+LSTM corrigiu essas discrepâncias para 0,01 m/s e 0,13 m/s, respectivamente. Em Feliz Deserto, o viés caiu de -0,39 m/s para -0,15 m/s.

Quanto ao erro quadrático médio (RMSE), observou-se uma diminuição marcante: em Feliz Deserto, o RMSE caiu de 1,75 m/s para 0,70 m/s (redução de ~55%); em Girau do Ponciano, de 2,53 m/s para 0,98 m/s (~62%); e em Água Branca, de 2,02 m/s para 1,05 m/s (~50%). Os valores de nRMSE também reforçaram essa melhoria relativa, passando de 26% para 11% em Feliz Deserto, 30% para 11% em Girau do Ponciano e 25% para 13% em Água Branca.

A melhoria na qualidade das simulações meteorológicas, proporcionada pelo refinamento dos dados simulados, pode impactar positivamente o planejamento e a operação de parques eólicos, especialmente em regiões com relevo complexo. Além disso, o aprimoramento na precisão dos dados meteorológicos pode contribuir para a otimização da alocação de recursos e para a expansão da geração de energia renovável no Brasil.

Vale ressaltar também a demanda por grandes volumes de dados confiáveis e bem distribuídos geograficamente, juntamente com a necessidade de monitoramento contínuo dos modelos para mitigar vieses. No Brasil, particularmente na região Nordeste, a escassez de medições meteorológicas confiáveis e bem distribuídas compromete a precisão das simulações e limita o potencial de otimização dos modelos de redes neurais. O desenvolvimento de estratégias para garantir a qualidade e a representatividade dos dados, bem como a automação

do ajuste e calibração desses modelos, serão aspectos cruciais para viabilizar a metodologia empregada neste estudo, bem como, sua aplicação em larga escala.

Para projetos futuros, melhorias adicionais podem aprimorar a modelagem do vento em terrenos complexos, onde a variação da rugosidade da superfície, as acelerações orográficas e os efeitos de canalização dificultam a simulação precisa do escoamento atmosférico. A integração de parâmetros dinâmicos, como o índice de área foliar e o comprimento de rugosidade, aliada a redes neurais mais avançadas e à calibração de esquemas de parametrização dos modelos atmosféricos, pode refinar a representação das interações entre o solo, a vegetação e a atmosfera, tornando a simulação de vento mais precisa e ampliando sua aplicação na avaliação de recursos eólicos.

6. REFERÊNCIAS

ABBEÓLICA (Associação Brasileira De Energia Eólica**)** (2024). **Boletim Anual de 2023**.

ADOMAKO, A. B., JAMSHIDI, E. J., YUSUP, Y., ELSEBAKHI, E., JAAFAR, M. H., ISHAK, M. I. S., LIM, H. S., & AHMAD, M. I. (2024). Deep learning approaches for bias correction in WRF model outputs for enhanced solar and wind energy estimation: A case study in East and West Malaysia. **Ecological Informatics**, *84*(November). https://doi.org/10.1016/j.ecoinf.2024.102898

ALEXANDER, M.; SCOTT, J. The influence of ENSO on air-sea interaction in the Atlantic. **Geophysical Research Letters**, v. 29, n. 14, p. 46-1-46–4, jul. 2002

ALVES, D., MENDONÇA, F., MOSTAFA, S. S., & MORGADO-DIAS, F. (2023). The Potential of Machine Learning for Wind Speed and Direction Short-Term Forecasting: A Systematic Review. **Computers**, *12*(10). https://doi.org/10.3390/computers12100206

AMARANTE, O. A. C.; SÁ, A. L.; ZACK, M. B. E. J. **Atlas do potencial eólico brasileiro**. 2001. 44f. Monografia (Tecnologia em Energia Eólica) - CEPEL, MME.

ARAUJO, M. L. S., KITAGAWA, Y. K. L., WEYLL, A. L. C., LIMA, F. J. L. DE, SANTOS, T. S. DOS, JACONDINO, W. D., SILVA, A. R., FILHO, M. DE C., BEZERRA, W. R. P., MELO FILHO, J. B. DE, SANTOS, A. Á. B., RAMOS, D. N. DA S., & MOREIRA, D. M. (2023). Wind Power Forecasting in a Semi-Arid Region Based on Machine Learning Error Correction. **Wind**, *3*(4), 496–512. https://doi.org/10.3390/wind3040028

ATKINSON, B.W. (1981). *Meso-Scale Atmospheric Circulations.* Londres. **Academic Press**.

BARTHELMIE, R. J.; PRYOR, S. C. Climate Change Mitigation Potential of Wind Energy. **Climate**, v. 9, 136, 2021. DOI: https://doi.org/10.3390/cli9090136

BASTOS, Í. G. P. et al. Previsão de Geração Fotovoltaica a partir de Dados Meteorológicos Utilizando Rede LSTM. **VIII Congresso Brasileiro de Energia Solar**, 2020

BENOIT, R., ROYER, A., DESJARDINS, S., & FORTIN, V. (2011). Bias correction of wind fields for wind energy applications. **Wind Engineering**, 35(4), 459–468. https://doi.org/10.1260/0309-524X.35.4.459

BRITO. L. S. (2018). Análise do Vento sobre o Nordeste do Brasil na reanálise centenária ERA-20C: Variabilidade Interanual e Extremos. **Dissertação (Mestrado em Meteorologia)** – Universidade de São Paulo, Instituto de Astronomia, Geofísica e Ciências atmosféricas, São Paulo, 2018.

BROWELL, J., MCMILLAN, D., & INFIELD, D. (2014). Forecasting wind power uncertainty using ensemble techniques. *Renewable* **Energy**, 68, 705–710. https://doi.org/10.1016/j.renene.2014.02.021

BYRKJEDAL Ø, BERGE E. 2008. **The use of WRF for wind resource mapping in Norway**.

CAO, J., XUE, W., MAO, R., & XIN, D. (2023). Wind power in forested regions: Power law extrapolation vs. lidar observation. **Journal of Wind Engineering and Industrial Aerodynamics**, *232*. https://doi.org/10.1016/j.jweia.2022.105281

CARVALHO D, ROCHA A, SILVA SANTOS C, PEREIRA R. 2013. Wind resource modelling in complex terrain using different mesoescale–microscale coupling techniques. **Appl. Energy 108**: 493–504.

CHE, G., ZHOU, D., WANG, R., ZHOU, L., ZHANG, H., & YU, S. (2024). Wind Energy Assessment in Forested Regions Based on the Combination of WRF and LSTM-Attention Models. **Sustainability (Switzerland)**, *16*(2). https://doi.org/10.3390/su16020898

CHE, Y., A. SALAZAR, A., PENG, S., ZHENG, J., CHEN, Y., & YUAN, L. (2022). A multi-scale model for day-ahead wind speed forecasting: A case study of the Houhoku wind farm, Japan. **Sustainable Energy Technologies and Assessments**, *52*(June 2021). https://doi.org/10.1016/j.seta.2022.101995

DA SILVA, J. K. A. (2007). Caracterização do Vento e Estimativa do Potencial Eólico para a Região de Tabuleiros costeiros (Pilar, Alagoas). **Dissertação (Mestrado em Meteorologia)**. Universidade Federal de Alagoas, Instituto de Ciências atmosféricas, Alagoas, 2007.

DA SILVA, M. B. L., BARRETO, F. T. C., COSTA, M. C. DE O., DA SILVA JUNIOR, C. L., & DE CAMARGO, R. (2025). Bias correction of significant wave height with LSTM neural networks. **Ocean Engineering**, *318*(November 2024), 120015. https://doi.org/10.1016/j.oceaneng.2024.120015

DE JONG, P., SÁNCHEZ, A. S., ESQUERRE, K., KALID, R. A., & TORRES, E. A. (2013). Solar and wind energy production in relation to the electricity load curve and hydroelectricity in the northeast region of Brazil. **Renewable and Sustainable Energy Reviews**, *23*, 526–535. https://doi.org/10.1016/j.rser.2013.01.050

DONADIO, L., FANG, J., & PORTÉ-AGEL, F. (2021). Numerical weather prediction and artificial neural network coupling for wind energy forecast. **Energies**, *14*(2). https://doi.org/10.3390/en14020338

DRANKA, G. G., & FERREIRA, P. (2020). Towards a smart grid power system in Brazil: Challenges and opportunities. **Energy Policy**, *136*, 111033. https://doi.org/10.1016/j.enpol.2019.111033

EHRET, U., ZEHE, E., WULFMEYER, V., WARRACH-SAGI, K., & LIEBERT, J. (2012). HESS Opinions "Should we apply bias correction to global and regional climate model data?". ***Hydrology and Earth System Sciences***, 16(9), 3391–3404. https://doi.org/10.5194/hess-16-3391-2012

ELETROBRÁS. (2008). **Estado de Alagoas Atlas Eólico**.

EPE (Empresa de Pesquisa Energética). (2024). **Balanço Energético Nacional 2024 - Relatório Síntese Ano base 2023**.

FIGUEIREDO. E. L. (2009). Análise Estatística E Sinótica Dos Ventos Máximos Diários Para A Cidade De Maceió-Al E A Criação De Um Software Sinótico Operacional. **Dissertação (Mestrado em Meteorologia)**. Universidade Federal de Alagoas. Instituto de Ciências atmosféricas, Alagoas, 2009.

GERON, Aurélien**.** *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2. ed. **Sebastopol: O'Reilly Media**, 2019.

GRELL, G. A. AND FREITAS, S. R., 2014: A scale and aerosol aware stochastic convective parameterization for weather and air quality modeling, **Atmos. Chem. Phys**., **14**, 5233-5250, doi:10.5194/acp-14-5233-2014.

GWEC (*Global Wind Energy Council).* (2024). **Global Wind Report 2024**.

HOCHREITER, S., & SCHMIDHUBER, J. (1997). Long short-term memory. **Neural computation**, **9**(8), 1735-1780

IACONO, et al., 2008: Radiative forcing by long–lived greenhouse gases: Calculations with the AER radiative transfer models. **J. Geophys**. *Res.*, **113**, D13103. doi:10.1029/2008JD009944.

JIMÉNEZ, P. A., & DUDHIA, J. (2012). Improving the representation of resolved and unresolved topographic effects on surface wind in the wrf model. *Journal of Applied Meteorology and Climatology*, *51*(2), 300–316. https://doi.org/10.1175/JAMC-D-11-084.1

JUNG, C., & SCHINDLER, D. (2021). The role of the power law exponent in wind energy assessment: A global analysis. *International Journal of Energy Research*, *45*(6), 8484–8496. https://doi.org/10.1002/er.6382

KARA, Y., AKALIN, I. A., DENIZ, N. G., DINÇ, U., ÜNAL, Z. F., & TOROS, H. (2023). Utilizing ANN for improving the WRF wind forecasts in Türkiye. *Earth Science Informatics*, *16*(3), 2167–2186. https://doi.org/10.1007/s12145-023-01003-w

KERAS. **Keras: The Python Deep Learning API**. [S. l.], 2024. Disponível em: https://keras.io/

KINGMA, DIEDERIK P.; BA, JIMMY LEI**.** Adam: A method for stochastic optimization. **arXiv preprint**, arXiv:1412.6980, 2014.

MARTINS, F. R., GUARNIERI, R. A., & PEREIRA, E. B. (2008). O aproveitamento da energia eólica. **Revista Brasileira de Ensino de Física**, 30(1), 1304.1-1304.13. https://doi.org/10.1590/S1806-11172008000100005

MOTA, F. B. S., SOUZA, V. C. O., ASSIREU, A. T. (2025). Previsão de Velocidade e Direção do Vento Utilizando Redes LSTM e Sensoriamento Remoto por LIDAR. **Anais do XXI Simpósio Brasileiro de Sensoriamento Remoto.**

NIU, et al., 2011: The community Noah land surface model with multiparameterization options (Noah–MP): 1. Model description and evaluation with local–scale measurements. **J. Geophys. Res.**, **116**, D12109. doi:10.1029/2010JD015139

OLIVEIRA, J. L.; COSTA, A. A. Estudo de variabilidade do vento em escala sazonal sobre o nordeste brasileiro utilizando o RAMS: os casos de 1973-1974 e 1982-1983. **Revista Brasileira de Meteorologia**, v. 26, n. 1, p. 53–66, 2011.

PLEIM, J. E. A Combined Local and Nonlocal Closure Model for the Atmospheric Boundary Layer. Part I: Model Description and Testing. **Journal of Applied Meteorology and Climatology**, v. 46, n. 9, p. 1383–1395, 1 set. 2007.

QURESHI, K. N., KHAN, R. A., & ALSHAHRANI, S. (2020). Wind power forecasting using deep learning based hybrid models. **IEEE Access**, 8, 169094–169107.

ROSA, C. DE O. C. S., CHRISTO, E. DA S., & COSTA, K. A. (2020). Assessing complementarity and optimising the combination of intermittent renewable energy sources using ground measurements. **Journal of Cleaner Production**, *258*, 120946. https://doi.org/10.1016/j.jclepro.2020.120946

SASSER, C., YU, M., & DELGADO, R. (2022a). Improvement of wind power prediction from meteorological characterization with machine learning models. **Renewable Energy**, *183*, 491–501. https://doi.org/10.1016/j.renene.2021.10.034

SAYEED, A., CHOI, Y., JUNG, J., LOPS, Y., ESLAMI, E., & SALMAN, A. K. (2023). A Deep Convolutional Neural Network Model for Improving WRF Simulations. **IEEE Transactions on Neural Networks and Learning Systems**, *34*(2), 750–760. https://doi.org/10.1109/TNNLS.2021.3100902

SCHULTZ, M. G., BETANCOURT, C., GONG, B., KLEINERT, F., LANGGUTH, M., LEUFEN, L. H., MOZAFFARI, A., & STADTLER, S. (2021). Can deep learning beat numerical weather prediction? **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, *379*(2194). https://doi.org/10.1098/rsta.2020.0097

SIWEK, K., OSOWSKI, S., & ŁAWRYŃCZUK, M. (2021). Forecasting of wind speed using LSTM neural network and hybrid models. **Energy**, 221, 119804.

SHI, L., ZHANG, Y., ZHANG, X., & CUI, X. (2022). A hybrid LSTM-based model for bias correction in regional climate model simulations. **Theoretical and Applied Climatology**, 148, 577–589.

SILVA, I. N. da. *Redes neurais artificiais para engenharia e ciências aplicadas*. 1. ed. São Paulo: **Artliber**, 2008

SILVA, A. R. (2011). Caracterização do vento e potencial eólico no estado de Alagoas. **Dissertação (Mestrado em Meteorologia)** - Universidade Federal de Alagoas. Instituto de Ciências atmosféricas, Alagoas, 2011.

SILVA, F. F. (2015). **Potencial Eólico Do Nordeste Brasileiro**.

SILVA, R. A. et al. Avaliação da Capacidade de Generalização de Arquiteturas de Redes Neurais na Previsão de Temperatura Máxima do Ar. **Congresso Brasileiro de Automática**, 2024.

SOUZA, N. B. P. DE, NASCIMENTO, E. G. S., SANTOS, A. A. B., & MOREIRA, D. M. (2022). Wind mapping using the mesoscale WRF model in a tropical region of Brazil. **Energy**, *240*(April 2022), 122491. https://doi.org/10.1016/j.energy.2021.122491

STETCO, A., DINMOHAMMADI, F., ZHAO, X., ROBU, V., FLYNN, D., BARNES, M., KEANE, J., & NENADIC, G. (2019). Machine learning methods for wind turbine condition monitoring: A review. **Renewable Energy**, *133*, 620–635. https://doi.org/10.1016/j.renene.2018.10.047

TAO, et al., 2016: High-resolution NU-WRF simulations of a deep convective-precipitation system during MC3E: Further improvements and comparisons between Goddard microphysics schemes and obser- vations. **J. Geophys. Res. Atmos**., **121**, 1278–1305. doi:10.1002/2015JD023986.

THEMEL, M. J., GOBIET, A., & LEUPRECHT, A. (2011). Empirical-statistical downscaling and error correction of regional climate models and its impact on the climate change signal. **Climatic Change**, 112(2), 449–468. https://doi.org/10.1007/s10584-011-0224-4

TSAI, W.-C., HONG, C.-M., TU, C.-S., LIN, W.-M., & CHEN, C.-H. (2023). A Review of Modern Wind Power Generation Forecasting Technologies. **Sustainability**, *15*(14), 10757. https://doi.org/10.3390/su151410757

TUY, S., LEE, H. S., & CHRENG, K. (2022). Integrated assessment of offshore wind power potential using Weather Research and Forecast (WRF) downscaling with Sentinel-1 satellite imagery, optimal sites, annual energy production and equivalent CO2 reduction. **Renewable and Sustainable Energy Reviews**, *163*(May), 112501. https://doi.org/10.1016/j.rser.2022.112501

WANG, Y., ZOU, R., LIU, F., ZHANG, L., & LIU, Q. (2021). A review of wind speed and wind power forecasting with deep neural networks. **Applied Energy**, *304*(April), 117766. https://doi.org/10.1016/j.apenergy.2021.117766

XIONG, X., ZOU, R., SHENG, T., ZENG, W., & YE, X. (2023). An ultra-short-term wind speed correction method based on the fluctuation characteristics of wind speed. **Energy**, *283*(April), 129012. https://doi.org/10.1016/j.energy.2023.129012

XU, W., LIU, P., CHENG, L., ZHOU, Y., XIA, Q., GONG, Y., & LIU, Y. (2021). Multi-step wind speed prediction by combining a WRF simulation and an error correction strategy. **Renewable Energy**, *163*, 772–782. https://doi.org/10.1016/j.renene.2020.09.032

YANG, M., GUO, Y., & HUANG, Y. (2023). Wind power ultra-short-term prediction method based on NWP wind speed correction and double clustering division of transitional

weather process. **Energy**, *282*(June), 128947. https://doi.org/10.1016/j.energy.2023.128947

ZHANG, Y., CUI, B., & CHEN, C. (2021). Post-processing wind speed forecasts using ensemble model output statistics and machine learning methods. ***Renewable Energy***, 170, 774–788. https://doi.org/10.1016/j.renene.2021.02.088

ZHANG, W., TIAN, M., HAI, S., WANG, F., AN, X., LI, W., LI, X., & SHENG, L. (2024). Improving the Forecasts of Coastal Wind Speeds in Tianjin, China Based on the WRF Model with Machine Learning Algorithms. **Journal of Meteorological Research**, *38*(3), 570–585. https://doi.org/10.1007/s13351-024-3096-z