

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS DA NATUREZA

ENGENHARIA AMBIENTAL

Guilherme Alcantara Barbosa Cunto

Avaliação dos impactos das mudanças climáticas na geração de energia eólica nos estados do
Rio Grande do Norte e Ceará

Buri

2025

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS DA NATUREZA

ENGENHARIA AMBIENTAL

Guilherme Alcantara Barbosa Cunto

Avaliação dos impactos das mudanças climáticas na geração de energia eólica nos estados do Rio Grande do Norte e Ceará

Trabalho de Conclusão de Curso apresentado como exigência parcial para a obtenção do grau de Bacharel em Engenharia Ambiental na Universidade Federal de São Carlos.

Orientação: Prof. Dr. Rafael de Oliveira Tiezzi

Buri

2025

Cunto, Guilherme Alcantara Barbosa

Avaliação dos impactos das mudanças climáticas na geração de energia eólica nos estados do Rio Grande do Norte e Ceará / Guilherme Alcantara Barbosa Cunto -- 2025.
40f.

TCC (Graduação) - Universidade Federal de São Carlos, campus Lagoa do Sino, Buri
Orientador (a): Rafael de Oliveira Tiezzi
Banca Examinadora: Rafael de Oliveira Tiezzi, Iuri Emmanuel de Paula Ferreira, Vinicius Rainer Boniolo
Bibliografia

1. Mudanças climáticas. 2. Inteligência artificial. 3. Modelos climáticos globais. I. Cunto, Guilherme Alcantara Barbosa. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)


DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Lissandra Pinhatelli de Britto - CRB/8 7539


UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS DA NATUREZA
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL

Folha de Aprovação


Assinatura dos membros da comissão examinadora que avaliou e aprovou a Defesa de Trabalho de Conclusão de Curso do(a) candidato(a) Guilherme Alcantara Barbosa Cunto, realizada em 13/11/2025:

Documento assinado digitalmente
 **RAFAEL DE OLIVEIRA TIEZZI**
Data: 26/11/2025 16:44:32-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rafael de Oliveira Tiezzi – Orientador(a)
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente
 **IURI EMMANUEL DE PAULA FERREIRA**
Data: 27/11/2025 08:44:08-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Iuri Emmanuel de Paula Ferreira
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente
 **VINICIUS RAINER BONIOLO**
Data: 27/11/2025 14:28:05-0300
Verifique em <https://validar.iti.gov.br>

Prof. Msc. Vinícius Rainer Boniolo
Programa de Pós Graduação em Ciências Ambientais – Universidade Federal de Alfnas

AGRADECIMENTO

Gostaria de agradecer meus orientadores Rafael de Oliveira Tiezzi, Danillo Roberto Pereira e Iuri Emmanuel de Paula por todo suporte e trabalho no desenvolvimento prolongado desse projeto, também gostaria de agradecer a todos os meus colegas que me incentivaram durante o processo de execução do projeto, com críticas e observações decisivas para o melhor desenvolvimento da pesquisa.

RESUMO

CUNTO, Guilherme. **Avaliação dos impactos das mudanças climáticas na geração de energia eólica nos estados do Rio Grande do Norte e Ceará.** 2025. Trabalho de Conclusão de Curso – Universidade Federal de São Carlos, *campus* Lagoa do Sino, Buri, 2025.

A energia eólica tem se destacado como uma das principais alternativas sustentáveis para a geração elétrica no Brasil. Entre os estados com maior potencial, o Rio Grande do Norte e o Ceará se sobressaem devido às condições climáticas e geográficas que favorecem ventos consistentes e de alta qualidade. Entretanto, a disponibilidade desse recurso é fortemente condicionada às variações climáticas, tornando essencial que o planejamento energético de longo prazo incorpore projeções confiáveis sobre o comportamento futuro dos ventos. Este estudo analisou cenários climáticos propostos pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC) e seus possíveis impactos sobre o setor eólico, utilizando saídas de Modelos Climáticos Globais (GCMs) regionalizados pelo modelo Eta (BESM, CanESM2, HadGEM2-ES e MIROC5), posteriormente ajustadas por técnicas de aprendizado de máquina. As séries históricas observacionais foram integradas às projeções dos modelos, resultando em uma modelagem híbrida de alta precisão para estimar tendências nas próximas três décadas. Os resultados indicam uma tendência geral de leve decréscimo nas velocidades médias dos ventos, variando entre 2% e 7% até meados do século. O Ceará apresenta comportamento mais estável e homogêneo, com reduções discretas e baixa variabilidade espacial, enquanto o Rio Grande do Norte evidencia diminuições mais heterogêneas, sobretudo em áreas interiores. Apesar das reduções projetadas, ambos os estados mantêm condições amplamente favoráveis para a expansão da geração eólica e para o fortalecimento da cadeia de produção do hidrogênio verde, consolidando o Nordeste como eixo estratégico na transição energética brasileira.

Palavras-chave: Energia Eólica; Planejamento Energético; Mudanças Climáticas; Modelos Climáticos Globais.

ABSTRACT

Wind energy has emerged as one of the main sustainable alternatives for electricity generation in Brazil. Among the states with the greatest potential, Rio Grande do Norte and Ceará stand out due to their favorable climatic and geographic conditions, which ensure strong and consistent wind regimes. However, the availability of this resource is highly dependent on climatic variability, making it essential that long-term energy planning incorporates reliable projections of future wind behavior. This study analyzed climate scenarios proposed by the Intergovernmental Panel on Climate Change (IPCC) and their potential impacts on the wind energy sector, using outputs from Global Climate Models (GCMs) regionalized through the Eta model (BESM, CanESM2, HadGEM2-ES, and MIROC5), subsequently refined through machine learning techniques. Historical observational series were integrated into these projections, resulting in a hybrid modeling framework capable of providing high-accuracy forecasts for the next three decades. The results indicate a general trend of slight decreases in mean wind speeds, ranging from 2% to 7% by the mid-21st century. Ceará shows a more stable and homogeneous pattern, with modest reductions and low spatial variability, while Rio Grande do Norte exhibits more heterogeneous declines, particularly in inland areas. Despite these projected reductions, both states remain highly favorable for wind power expansion and for strengthening the green hydrogen production chain, consolidating the Northeast region as a strategic axis in Brazil's energy transition.

Keywords: Wind Energy; Energy Planning; Climate Change; Global Climate Models.

LISTA DE FIGURAS

Figura 1 – Oferta interna de energia no Brasil ao decorrer dos anos.....	17
Figura 2 – Dados observados das estações selecionadas do Rio Grande do Norte.....	24
Figura 3 – Validação do modelo Random Forest nas estações do estado do Ceará.....	26
Figura 4 – Validação do modelo Random Forest nas estações do estado do Rio Grande do Norte.....	27
Figura 5 – Análise do MAE e MAPE.....	28
Figura 6– Projeção pelo Random Forest nas estações do estado do Ceará de 2024 até 2055.....	31
Figura 7 – Projeção pelo Random Forest nas estações do estado do Rio Grande do Norte de 2025 até 2054.....	32

LISTA DE ABREVIATURAS E SIGLAS

BEN Balanço Energético Nacional

GCM Global Climate Model

IPCC Intergovernmental Panel on Climate Change

AR Assessments Reports

PIB Produto Interno Bruto

MME Ministério de Minas e Energia

COP Conferência das Partes

RCP Representative Concentration Pathway

CCEE Câmara de Comercialização de Energia Elétrica

EPE Empresa Pesquisa Energética

PDE Plano Decenal de Expansão de Energia

PNE Plano Nacional de Expansão de Energia

CEPEL Centro de Pesquisas de Energia Elétrica

CANESM2 Canadian Earth System Model versão 2

MIROC Model for Interdisciplinary Research on Climate versão 5

HADGEM 2 ES Hadley Centre Global Environment Model versão 2

BESM The Brazilian Earth System Model

ML Machine Learning

CPTEC Centro de Previsão de Tempo e Estudos Climáticos

INPE Instituto Nacional de Pesquisas Espaciais

DRL Aprendizado por reforço profundo

CNNs Redes neurais convolucionais

MAE Erro absoluto médio

MAPE Erro percentual absoluto médio

SUMÁRIO

1	INTRODUÇÃO	12
2	PRESSUPOSTOS TEÓRICOS/ FUNDAMENTAÇÃO TEÓRICA	14
2.1	ENERGIAS RENOVÁVEIS NO BRASIL	14
2.2	ENERGIA EÓLICA NO BRASIL	14
2.2.1	Contextualização para os estados Rio Grande do Norte e Ceará	14
2.3	IPCC E MUDANÇAS CLIMÁTICAS	14
2.4	MODELOS CLIMÁTICOS GLOBAIS (GCMS)	14
2.4.1	The Brazilian Earth System Model (BESM)	14
2.4.2	Canadian Earth System Model versão 2 (CanESM2)	14
2.4.3	Hadley Centre Global Environment Model versão 2 (HadGEM2-ES)	14
2.4.4	Model for Interdisciplinary Research on Climate versão 5 (MIROC5)	14
2.5	MODELO ETA	14
2.6	INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA EM SÉRIES TEMPORAIS	14
3	METODOLOGIA	21
4	RESULTADOS E DISCUSSÃO	23
4.1	ANÁLISE DOS DADOS OBSERVADOS	23
4.2	VALIDAÇÃO DOS MODELOS DE PREVISÃO	25
4.3	PREVISÕES E TENDÊNCIAS DAS VELOCIDADES DOS VENTOS DOS ANOS DE 2024 E 2054	31
5	CONCLUSÕES	36
	REFERÊNCIAS	37

1 INTRODUÇÃO

As mudanças climáticas são pauta importante no âmbito das grandes tomadas de decisão a nível global, evidenciando a necessidade de prever assertivamente suas consequências nos setores fundamentais da economia e bem-estar social. O tópico de produção de energia passa a ser uma questão chave nas discussões sobre esse tipo de mudança, pelo fato de a produção energética limpa depender fundamentalmente de recursos naturais que estão intrinsecamente correlacionados a quaisquer alterações climáticas (LUCENA *et al.*, 2009).

Uma maior variação da matriz energética gera estabilidade para o setor energético frente às mudanças climáticas, logo a energia eólica desponta como uma alternativa viável para fortalecer o setor energético nacional e internacional ganhando amplo destaque e investimento a partir da última década (SIMAS; PACCA, 2014). O Brasil detém grande potencial não explorado na sua produção eólica através da abundância e qualidade do recurso disponível em diferentes partes do território nacional, por conta de sua extensão territorial e características climatológicas privilegiadas. Entender a disponibilidade futura do recurso eólico é crucial para planejar investimentos, expansão na capacidade produtiva e desenvolver novas tecnologias para o setor (LUCENA *et al.*, 2010).

A compreensão do cenário climático futuro é fundamental para o desenvolvimento do setor energético brasileiro e para a consolidação do Brasil como país chave na transição energética global, podendo fornecer informações valiosas para expansão e para o planejamento estratégico das políticas energéticas, considerando que as mudanças climáticas irão influenciar diretamente a produção de energia em escala global (LUCENA *et al.*, 2010). Neste caso, nem só a energia eólica, mas a maior parte da geração de energia no Brasil, visto que nos últimos anos as energias renováveis são responsáveis por gerar a maior parte da energia elétrica do país, segundo dados do Balanço Energético Nacional 2024 (ano base 2023) a energia elétrica proveniente de fontes hidráulicas representou cerca de 58,9% da produção brasileira, seguida das fontes de geração eólica e solar com, 13,2% e 7% respectivamente (EPE, 2024).

O futuro climático incerto tem ganhado ênfase na academia e seu comportamento começa a ser estudado a partir do desenvolvimento de uma série de modelos que projetam diferentes cenários que esboçam as mudanças climáticas e seus padrões de comportamento, através dos Modelos Climáticos Globais (*Global Climate Models*, GCMs) (CHOU *et al.*, 2014). Os modelos se baseiam na análise de diversas variáveis climatológicas que são

afetados pelas mudanças climáticas, esse tipo de estudo é amplamente difundido em diferentes países e instituições, considerando os apontamentos levantados pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2013) sendo a referência global neste tema de pesquisa. Portanto, a partir do IPCC são levantados cenários que buscam refletir diferentes futuros, variando de situações climatológicas menos críticas até cenários extremos.

Os modelos climáticos globais são ferramentas computacionais complexas que dividem o planeta em uma malha tridimensional e a partir dela calcula-se as variáveis climáticas essenciais, como temperatura, umidade e padrões de circulação, por meio de equações físicas que descrevem fenômenos naturais, como a transferência de calor e dinâmica de fluidos. São comumente utilizados para projetar futuros climáticos a partir de parâmetros levantados pelo IPCC. A confiabilidade pode ser garantida a partir da reprodução de padrões climáticos históricos, trazendo robustez aos modelos (IPCC, 2021).

A fim de aumentar o detalhamento e a assertividade das projeções para situações mais específicas, os modelos globais comumente são regionalizados em quadrantes menores (*downscaling*). Os modelos que foram regionalizados, através de *downscaling*, para o Brasil são os seguintes; BESM, CanESM2, HadGEM2-ES e o Miroc5. Esta técnica visa reduzir a escala geográfica permitindo que o modelo tenha uma maior precisão. O Instituto Nacional de Pesquisas Espaciais (INPE) é o responsável pela regionalização dos dados no Brasil (CHOU, 2014).

Como é inato das projeções apresentarem problemas de assertividade quando muito genéricas e abrangentes, utilizam-se técnicas de correção e ajuste de viés a partir do histórico climatológico da região para o melhoramento da precisão das previsões. Atualmente a utilização de modelos de inteligência artificial é amplamente difundida em ajustes de séries temporais e para a criação de projeções precisas através do seu processo de aprendizagem, apesar de recente esse tipo de abordagem tem se mostrado cada vez mais eficiente para criação de novos modelos com índices de assertividade significativamente maiores que outras abordagens (SHARIFZADEH; SIKINIOTI-LOCK; SHAH, 2019).

Este trabalho investiga o impacto das mudanças climáticas sobre a disponibilidade do recurso eólico no Nordeste brasileiro, com foco em 12 estações. O problema central é a incerteza sobre a evolução das velocidades médias do vento em escala local e decenal, que compromete o planejamento energético. O objetivo é quantificar alterações projetadas entre 2013 e 2054, calibrar modelos estatísticos com séries observacionais, comparar respostas dos regressores aos modelos climáticos e estimar variações percentuais por década. O estudo se justifica pela relevância estratégica da energia eólica para a matriz elétrica.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ENERGIAS RENOVÁVEIS NO BRASIL

O Brasil no cenário elétrico internacional é uma grande referência de produção sustentável, principalmente pela ampla utilização de fontes renováveis, algo que existe em abundância no país.

Pensando nos desafios futuros do abastecimento energético nacional, o país conta com valiosos recursos de planejamento do setor. Como o Plano Decenal de Expansão de Energia (PDE) e o Plano Nacional de Expansão de Energia (PNE) elaborados pela Empresa de Pesquisa Energética (EPE) que coordena esse tipo de planejamento, responsável pela estratégia de funcionamento energético do país como instituição federal (PAO; FU, 2013). As ferramentas de planejamento são responsáveis por estabelecer diretrizes e metas estratégicas a fim de fornecer as condições necessárias para uma expansão saudável e economicamente viável. Por levarem em conta cenários de longo prazo, o entendimento das possíveis alterações climáticas são peça chave para o aumento da qualidade do planejamento energético brasileiro, otimizando as tomadas de decisão para políticas públicas mais eficientes e trazendo a possibilidade de maiores investimentos do setor privado permitindo com que a expansão do setor energético seja ainda mais acelerada e eficiente (RUFFATO-FERREIRA *et al.*, 2017).

O Plano Nacional de Expansão de Energia (PNE), com horizonte de 20 a 30 anos, define estratégias para diversificar a matriz energética, priorizando fontes renováveis, redução de emissões e adaptação climática. Já o Plano Decenal de Expansão de Energia (PDE), atualizado anualmente, detalha ações para a década seguinte, como expansão de infraestrutura (usinas, transmissão) e integração tecnológica. Ambos, coordenados pela Empresa de Pesquisa Energética (EPE), alinham-se às políticas do Ministério de Minas e Energia, garantindo segurança e sustentabilidade no abastecimento.

Enquanto o PNE orienta transições estruturais de longo prazo, o PDE opera como ferramenta dinâmica, ajustando-se a variações socioeconômicas principalmente baseando-se principalmente em indicadores como o PIB e a renda per capita. A EPE viabiliza estudos técnicos, modelagens de demanda e consultas a agentes públicos, privados e sociedade, assegurando transparência e aderência às metas nacionais. Critérios ambientais, como avaliações de impacto, reforçam o compromisso com o desenvolvimento sustentável, algo ainda incipiente no planejamento energético a nível federal no Brasil (PAO; FU, 2013).

2.2 ENERGIA EÓLICA NO BRASIL

A energia eólica foi experimentalmente implementada no Brasil a partir da década de 1990 na cidade de Fernando de Noronha em Pernambuco, a princípio o desenvolvimento foi lento devido a questões técnicas e burocráticas, bem como o pouco interesse no aporte de capital nesse novo modelo de produção energético, pelo seu elevado custo agregado para implementação aliada a pouca infraestrutura estabelecida (JUÁREZ *et al.*, 2014).

A elaboração do Atlas Eólico Brasileiro de 2000 foi um marco fundamental para o setor eólico brasileiro. Desenvolvido pelo Centro de Pesquisas de Energia Elétrica (CEPEL, 2000) trouxe à tona um imenso potencial inexplorado para a produção de energia eólica em solo nacional, sobretudo nas zonas litorâneas da costa nordeste do país, nos estados do Rio Grande do Norte, Ceará, Bahia, Piauí e Maranhão. No geral, o estudo indicava um potencial produtivo de cerca de 142 GW.

A partir dos anos 2000, uma série de estudos revelaram o alto potencial brasileiro para produção eólica, que poderia se tornar um grande aliado à diversificação da matriz energética do país junto às hidrelétricas predominantes no setor elétrico. Um fato relevante aliado ao fortalecimento da estrutura de produção elétrica, principalmente atrelada ao perfil brasileiro de diversificação é que em períodos de seca a qualidade do vento para a produção eólica melhora, portanto seu pico ocorre quando a produção hidrelétrica está em baixa, possibilitando um equilíbrio na oferta de energia (GELLER, *et al.*, 2004).

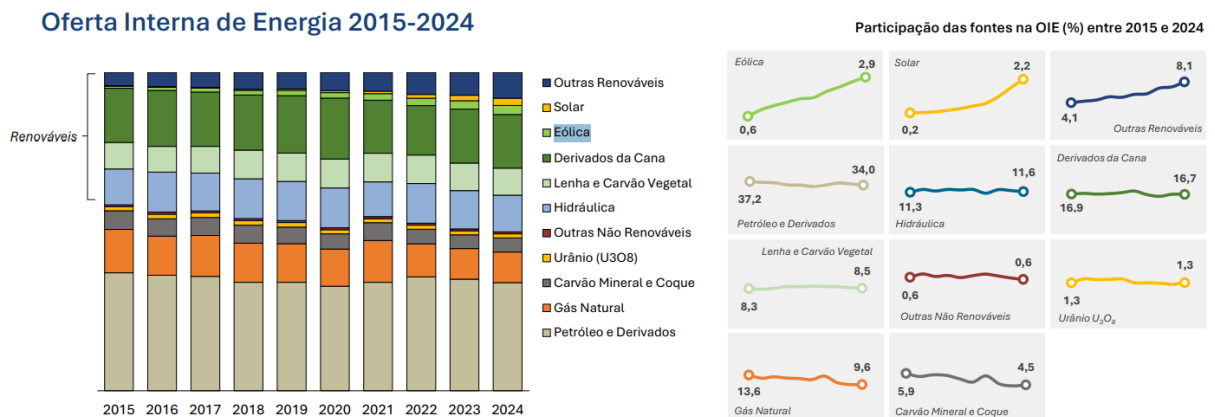
A sazonalidade da produção hidrelétrica possui seu pico nos meses chuvosos, principalmente durante o verão, diferentemente da produção eólica que apresenta picos durante o inverno nos meses de julho a outubro (CCEE, 2023). O que proporciona um equilíbrio maior no uso de diferentes tipos de energia, auxiliando na segurança energética do país e no seu fortalecimento econômico (GELLER, *et al.*, 2004).

Com base nos dados mais recentes do Balanço Energético Nacional (BEN) 2025, divulgado pelo Ministério de Minas e Energia (MME) e pela Empresa de Pesquisa Energética (EPE), referente ao ano-base de 2024, a matriz energética brasileira mantém sua posição de destaque global, com 88,2% da geração elétrica proveniente de fontes renováveis. A energia eólica, em conjunto com a solar, continua em expansão acelerada, representando 23,7% da produção total de eletricidade do país, com crescimento de 12,4% para a fonte eólica e impressionantes 39,6% para a solar fotovoltaica em relação ao ano anterior, a energia eólica representa a fatia de 14,8% da produção de energia elétrica no Brasil. As hidrelétricas permanecem como a principal fonte, embora com ligeira redução de 1,0% em sua

participação, enquanto o gás natural registrou significativa expansão de 23,9%, refletindo seu papel na complementaridade da matriz. Na matriz energética primária, as renováveis representaram 47% do total, com destaque para os biocombustíveis, que consolidam o Brasil como economia de baixo carbono. O consumo energético por setores mostra os transportes como maior demandante, seguido pela indústria, que vem aumentando o uso de biomassa e eletricidade, e pelo setor residencial, com maior penetração de gás natural e eletricidade. Esses resultados reforçam a trajetória brasileira de descarbonização e segurança energética, alinhada com políticas como o RenovaBio e investimentos em hidrogênio e combustíveis sustentáveis.

O Brasil saltou de 15 GW de capacidade instalada eólica em 2019 para mais de 30 GW em 2024, consolidando-se como o 6º maior produtor global de energia eólica. Esse crescimento está alinhado com políticas de diversificação da matriz e transição energética, com previsão de novos leilões e projetos para os próximos anos (BEN, 2025).

Figura 1. Oferta interna de energia no Brasil ao decorrer dos anos



Fonte: BEN, 2025

2.2.1 Contextualização para os estados Rio Grande do Norte e Ceará

Os estados são peças chave na produção de energia eólica sendo parte dos principais produtores do país, grandes responsáveis por tornar o nordeste brasileiro o local mais atrativo e produtivo do Brasil nesse quesito. Devido à sua localidade, próximos à costa, os ventos apresentam alta qualidade como recurso energético, pela velocidade, turbulência e constância (CEPEL, 2000).

Segundo dados da Câmara de Comercialização de Energia Elétrica (CCEE, 2022), em 2022 o estado do Rio Grande do Norte apresentou uma geração média de 23,20 TWh e o

Ceará 7,06 TWh, classificado entre os cinco maiores produtores do país. Segundo dados da Associação Brasileira de Energia Eólica, os dois estados somaram aproximadamente 36 TWh no ano de 2024, apresentando um aumento de 17% em dois anos.

Ambas regiões apresentam grande potencial inexplorado com a construção de novos empreendimentos, em conjunto com um aumento na produtividade da produção energética com novas tecnologias que abrangem maiores faixas de velocidade de vento, somado a capacidade já instalada potencializaria ainda mais a produção de energia (JUÁREZ *et al.*, 2014).

2.3 IPCC E MUDANÇAS CLIMÁTICAS

O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) tem como objetivo fornecer avaliações científicas sobre as mudanças climáticas, suas causas, impactos e possíveis estratégias de mitigação, considerando uma ampla base de dados científicos recentes, avaliando e sintetizando as informações com o intuito de fornecê-las de maneira objetiva para a comunidade internacional. Isso ocorre de diversas formas, principalmente através da publicação periódica de relatórios e pela realização de conferências internacionais que envolvem praticamente todos os países na Conferência das Partes (COPs) (IPCC, 2021).

Os relatórios de avaliação (do inglês *Assessment Report* - AR), normalmente publicados em intervalos de 5 a 7 anos, apresentam avanços significativos em relação às mudanças climáticas e principalmente estabelecem a correlação entre as ações humanas e as alterações do clima. Esses relatórios servem como base para a elaboração dos modelos climáticos globais (GCMs) por fornecerem informações robustas sobre as alterações no clima, sendo usual para grande parte dessas modelagens, que se atualizam e se aprimoram à medida que novos relatórios são publicados (IPCC, 2021).

No *Fifth Assessment Report* (AR5) foram estabelecidos cenários chamados de Caminhos Representativos de Concentração (RCPs), fundamentais para estimar futuras concentrações atmosféricas de gases do efeito estufa desde o ano vigente até 2100. o AR5 publicou 4 RCPs variando do cenário mais otimista de concentração até o mais pessimista, estes são o RCP2.6, RCP4.5, RCP 6.0 e RCP8.5 (IPCC, 2013), os números 2.6, 4.5, 6.0 e 8.5 equivalem a quantidade de radiação em W/m^2 , estes dados são usados pelos modelos globais e regionais para a modelagem de impactos futuros das mudanças climáticas.

2.4 MODELOS CLIMÁTICOS GLOBAIS (GCMs)

Os modelos climáticos globais (GCMs) cumprem papel fundamental na caracterização dos impactos causados pelas mudanças climáticas, nos diferentes cenários apontados pelo IPCC. Instituições de pesquisa ao redor do mundo oferecem novos modelos com características também distintas, que por sua vez geram previsões com características próprias e ao compará-las é possível identificar tendências e vieses de cada modelagem. Conforme descrito abaixo, serão abordadas as principais formas de modelagens matemáticas atualmente utilizadas (CHOU *et al.*, 2014).

2.4.1 *The Brazilian Earth System Model (BESM)*

É um modelo espectral desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), considera 28 níveis verticais e 50 níveis no oceano, sua resolução varia de $0,25^\circ$ a $2^\circ \times 1^\circ$ (lat $^\circ$ x long $^\circ$), contemplando 12 tipos de vegetações diferentes. Além disso, o sistema utiliza ainda interações radioativas e sistema de interação entre nuvens convectivas (CHOU *et al.*, 2014).

2.4.2 *Canadian Earth System Model versão 2 (CanESM2)*

O modelo desenvolvido pelo Centro Canadense de Modelagem e Análise Climática possui resolução equivalente a $2,8125^\circ \times 2,8125^\circ$ (lat $^\circ$ x long $^\circ$) e abrange 35 níveis atmosféricos, 9 tipos de vegetações e 3 sistemas vegetativos diferentes. Utiliza-se de um sistema de vegetação dinâmica incluindo, portanto, diversos comportamentos da vegetação, respondendo a possíveis alterações no uso da terra e alterações de clima e dióxido de carbono (HUA *et al.*, 2014).

2.4.3 *Hadley Centre Global Environment Model versão 2 (HadGEM2-ES)*

Desenvolvido pela *Met Office Hadley Center* do Reino Unido, possui uma resolução equivalente a $1,875^\circ \times 1,275^\circ$ (lat $^\circ$ x long $^\circ$) e 38 níveis atmosféricos, no oceano o sistema trabalha com 40 níveis oceânicos, verticais e horizontais. Sendo um modelo da categoria de sistema terrestre com representação do ciclo de carbono, modelado a partir da dinâmica da vegetação. Distinguem 5 tipos funcionais de plantas, árvores de folha larga e agulha, grama e arbustos. No modelo estão incluídas a química atmosférica, aerossol com carbono orgânico e representação de poeira (CHOU *et al.*, 2014).

2.4.4 *Model for Interdisciplinary Research on Climate versão 5 (MIROC5)*

A instituição responsável pelo modelo é a Agência Japonesa de Ciência e Tecnologia Terra-Marinha do Instituto de Pesquisas Atmosféricas e Oceânicas. O modelo abrange uma

extensão espectral de 150 km e possui 40 níveis atmosféricos verticais, a partir de uma resolução de $1,41^\circ \times 1,41^\circ$, além disso são consideradas, a microfísica das nuvens junto ao cálculo da radiação em até 6 camadas de solo e 3 tipos de vegetação. O sistema também representa o roteamento dos rios e o albedo da neve, além de considerar a termodinâmica e a dinâmica do gelo marinho, as características completas do sistema estão em WATANABE *et al.*, 2010.

2.5 MODELO ETA

Esse modelo é uma adaptação dos modelos climáticos globais (GCMs), com o intuito de melhorar a precisão dos dados gerados a partir dos modelos globalizados, especificamente para a América do Sul e Central, vem sendo amplamente utilizado no âmbito de mudanças climáticas pelo Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE) desde 2010 (LYRA *et al.*, 2017).

O sistema pode ser acoplado aos modelos globais, o que permite simular as condições futuras com maior riqueza em detalhes, em parte por conta de um maior número de variáveis de entrada, como as características do relevo e topografia da região e também por sua maior resolução. O modelo trabalha com grades de $0,20^\circ \times 0,20^\circ$ de latitude e longitude, contemplando 38 níveis verticais (LYRA *et al.*, 2017).

2.6 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA EM SÉRIES TEMPORAIS

A utilização da inteligência artificial (IA) e do aprendizado de máquina (ML) em séries temporais climáticas representa uma melhora grande na capacidade de interpretar, entender e criar projeções de fenômenos atmosféricos complexos. De forma diferente dos modelos climáticos comuns, que por sua vez atuam de forma simplificada em situações de interações não lineares e que por sua vez apresentam fatores limitantes ao tentar representar eventos extremos, com o aprendizado de máquina, a identificação de padrões não ocasionais e dinâmicos se torna mais evidente em grandes volumes de dados (DUEBEN; BAUER, 2018). Por esse motivo, tem se notado um aumento constante no desenvolvimento de novos modelos e métodos preditivos, com uma acurácia e assertividade notadamente maior às projeções tradicionais (RASP *et al.*, 2018; CHEN *et al.*, 2023). As redes neurais profundas, têm sido aplicadas para melhor a simulação de processos de alta dimensionalidade, exatamente como é a relação entre a emissão de gases de efeito estufa e a variação da temperatura global e os demais indicadores climatológicos, a fim de aumentar a previsibilidade das mudanças

climáticas e, sendo assim, a eficiência de políticas de mitigação e planejamento energético (RASP *et al.*, 2018; CHEN *et al.*, 2023).

Para a geração eólica, a previsão da velocidade dos ventos é essencial para determinar uma operação eólica e o seu dimensionamento. Porém, os modelos climáticos globais e regionalizados para a circulação atmosférica, embora eficaz quando se olha em escala macro, geralmente falham quando os utilizamos para a realização de análises que visam capturar padrões de vento em microescala e também para efeitos de turbulências, que acabam sendo importantes para estimar em curto prazo a produção de energia. Nesse cenário, os algoritmos de aprendizado de máquina surgem como ferramentas complementares aos modelos climáticos, capazes de ajustar previsões às condições reais de cada localidade. Modelos lineares, como a regressão linear múltipla, continuam relevantes na identificação de relações entre variáveis meteorológicas e produção média de energia (JUNG; BROADWATER, 2014). Contudo, métodos mais robustos, como os modelos de ensemble Random Forest e Gradient Boosting, destacam-se por sua habilidade em trabalhar com relações não lineares e reduzir incertezas em regiões de vento intermitente.

O Random Forest tem sido amplamente empregado na previsão da geração horária de energia a partir de dados históricos de vento, umidade e topografia (TSAI *et al.*, 2023), enquanto o Gradient Boosting se mostra eficaz em cenários de alta variabilidade atmosférica, otimizando estratégias de manutenção preditiva e prevenindo falhas (XIONG *et al.*, 2022). Outros algoritmos, como o K-Nearest Neighbors (KNN) e o Support Vector Regression (SVR), também têm aplicações consolidadas: o primeiro compara padrões atuais de vento com históricos para estimar a produção em horizontes diários ou semanais (LARA-FANEGO *et al.*, 2016), e o segundo modela relações não lineares entre a velocidade do vento e vibrações mecânicas em turbinas, auxiliando na detecção precoce de desgastes.

Além das aplicações operacionais, o aprendizado de máquina tem ganhado importância na projeção dos impactos das mudanças climáticas sobre o regime eólico. Algoritmos como as redes neurais convolucionais (CNNs) têm sido aplicados à análise de dados de modelos climáticos globais (CMIP6), possibilitando avaliar como diferentes cenários de emissões (RCPs) podem alterar a distribuição e intensidade dos ventos (PRYOR *et al.*, 2020). O Random Forest, vêm sendo utilizado para estimar riscos e vulnerabilidades associados a eventos climáticos extremos, como ciclones e tempestades tropicais, capazes de elevar custos de manutenção e reduzir a disponibilidade operacional de turbinas (ROSE; APT, 2012). Complementarmente, abordagens mais recentes de aprendizado por reforço profundo

(Deep Reinforcement Learning – DRL) permitem otimizar de forma adaptativa a operação e o posicionamento de turbinas, ajustando variáveis como altura das torres e localização de novos parques com base em projeções de ventos futuros (JUNG; SCHINDLER, 2022). Essas aplicações demonstram que a integração entre IA e modelagem climática oferece uma estrutura metodológica poderosa, capaz de reduzir incertezas, aprimorar a previsão energética e fortalecer o planejamento estratégico da geração eólica frente às transformações climáticas globais.

3 METODOLOGIA

Foram utilizados dados privados e confidenciais de quatro complexos eólicos, que abrangem um total de 30 estações de medição de vento, distribuídos entre os estados do Rio Grande do Norte e Ceará. Para garantir com que a análise posterior dos dados apresente resultados coerentes e satisfatórios com o objetivo proposto, dentre todas as estações com dados disponibilizados, foram selecionadas apenas estações cujas medições se iniciaram em 2016 ou antes, com frequências horárias e medições de velocidade do vento feitas em alturas que variam entre 80 e 123 metros.

Tabela 1. Estações do Ceará

Ceará	Altura de Medição (m)	Elevação (m)	Data de Início
SR1	80	672	29/03/2015
SR2	80	770	26/03/2015
SR3	80	690	29/03/2015
SR4	80	791	27/03/2015
SR5	80	724	27/03/2015

Fonte: autoria própria, 2025

Tabela 2. Estações do Rio Grande do Norte

Rio Grande do Norte	Altura de Medição (m)	Elevação (m)	Data de Início
SM1	123	198	02/05/2019
SM2	123	223	27/11/2019
SM3	123	258	02/05/2021
SM4	123	227	08/05/2021

SM5	123	179	08/05/2021
SM6	123	196	16/09/2021
SM7	123	267	01/12/2021
SM8	123	234	17/09/2021
SM9	123	212	28/11/2019
SM10	123	230	12/12/2019
SM11	123	226	10/02/2022
SM12	123	122	29/11/2019
SM13	123	177	30/11/2019
SM14	123	195	11/02/2022
JC1	80	229	06/07/2011
JC2	95	257	19/02/2016
JC3	95	234	23/02/2016
JC4	80	212	30/04/2011
JC5	95	226	01/09/2018
LN1	90	712	29/07/2013
LN2	80	693	01/07/2014
LN3	90	719	05/03/2014
LN4	80	660	01/10/2014
LN5	80	711	01/08/2013
LN6	80	571	24/03/2017
LN7	80	393	24/03/2017

Fonte: autoria própria, 2025

Além das séries temporais históricas obtidas, foram utilizadas projeções climáticas dos modelos regionais EtaBESM, EtaCanESM2, EtaHadGEM2-ES e EtaMiroc5, que foram extraídas do sistema “Projeta”, desenvolvido pelo CPTEC/INPE. Essas projeções foram geradas em quadrantes de 20x20km e ajustadas para as coordenadas geográficas das estações eólicas estudadas, utilizando os cenários de concentração de gases de efeito estufa RCP4.5 e RCP8.5. A variável climática selecionada foi a velocidade do vento a 100 metros de altura (W100), com uma frequência diária. As projeções iniciaram entre 2011 e 2016, dependendo da disponibilidade de dados em cada estação (CHOU *et al.*, 2014).

Os dados reais, obtidos em frequências horárias, foram transformados em dados

trimestrais e anuais para análise e comparação com as projeções climáticas. Da mesma forma, as projeções climáticas, originalmente em frequência diária, também foram transformadas em dados trimestrais e anuais, permitindo a uniformização da frequência dos dados. Essas projeções climáticas e os dados observados foram usados tanto para o treinamento quanto para o teste dos modelos preditivos, possibilitando uma análise detalhada das próximas tendências nas quais as regiões podem experimentar em relação à velocidade dos ventos nas regiões estudadas (RUFFATO-FERREIRA *et al.*, 2017; BISHOP, 2006).


A engenharia de características e a criação de séries defasadas, utilizaram de uma defasagem de até 182 dias para capturar padrões sazonais e de longo prazo nas medições de vento. O conjunto de dados foi dividido em treino e teste, sendo os dados até 2020 usados para treinamento e os dados a partir de 2021 até 2024 utilizados para validação dos modelos. Os modelos de regressão, como Regressão Linear, Decision Tree, Random Forest, Gradient Boosting, KNN e SVR, foram aplicados para gerar as previsões, com as métricas de avaliação MAE (Erro Absoluto Médio) e MAPE (Erro Percentual Absoluto Médio) sendo utilizadas para avaliar a performance das previsões (MITCHELL, 1997 e GOODFELLOW, 2016).

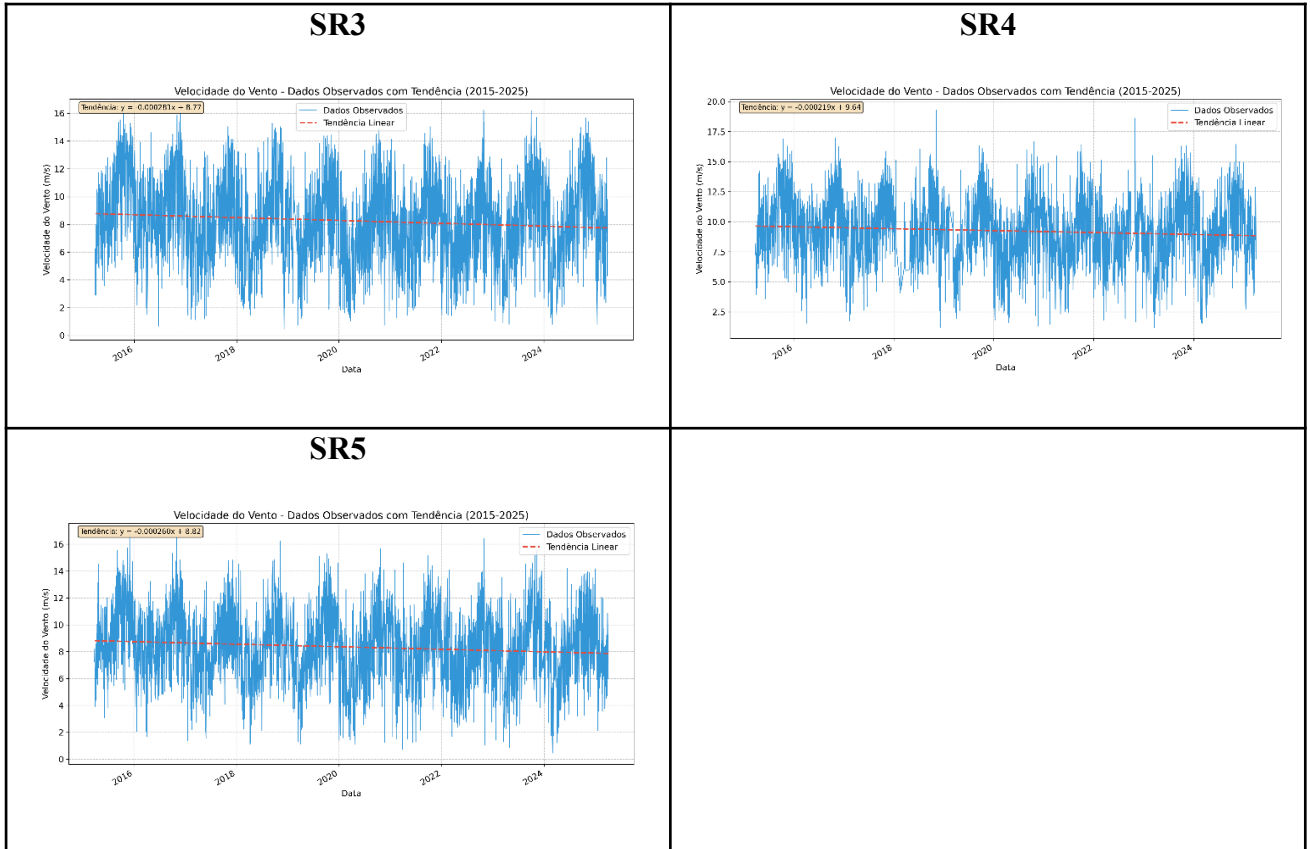
Para a avaliação da performance das previsões, o MAE e o MAPE foram comparados a uma projeção realizada pelo PROJETA, a projeção em questão foi a EtaHADGEM2-ES que servia de parâmetro para medir o grau de assertividade do novo modelo criado com base no aprendizado de máquina aplicado.

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE DOS DADOS OBSERVADOS

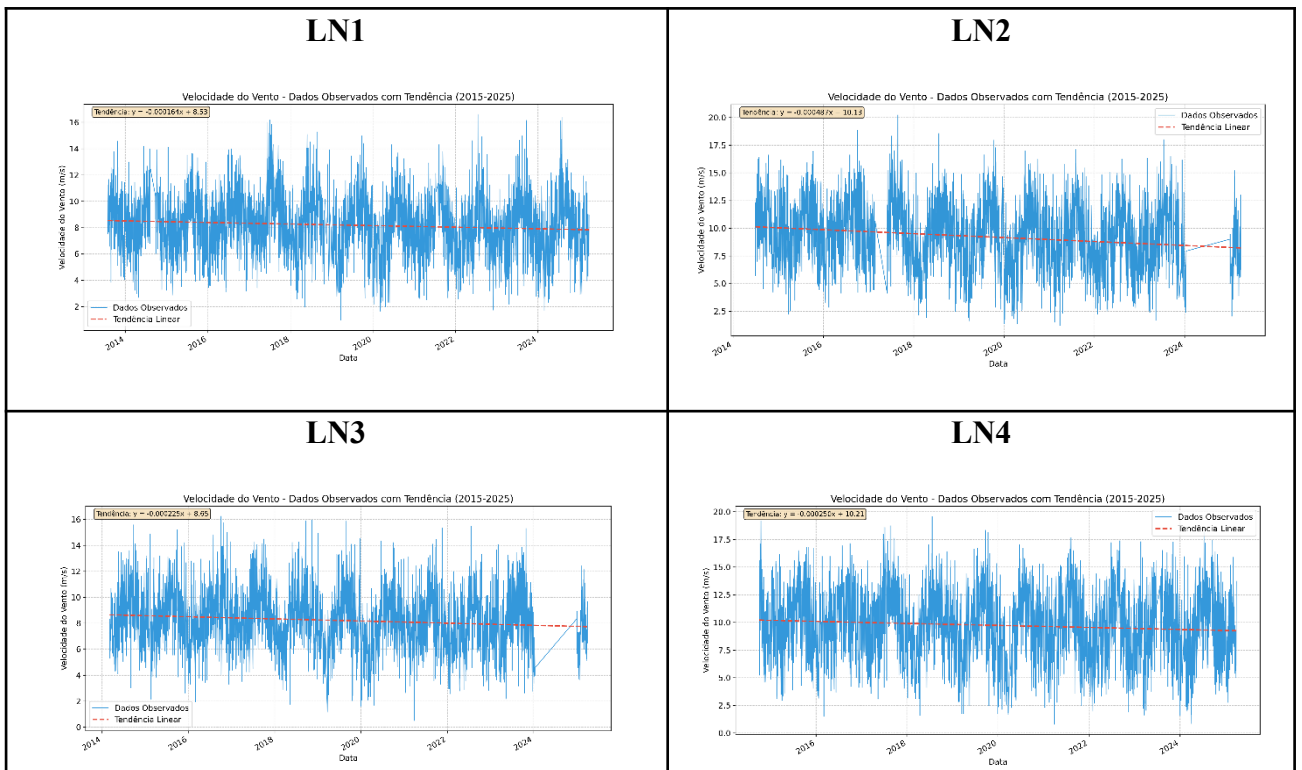
Figura 2. Dados observados das estações selecionadas do Ceará

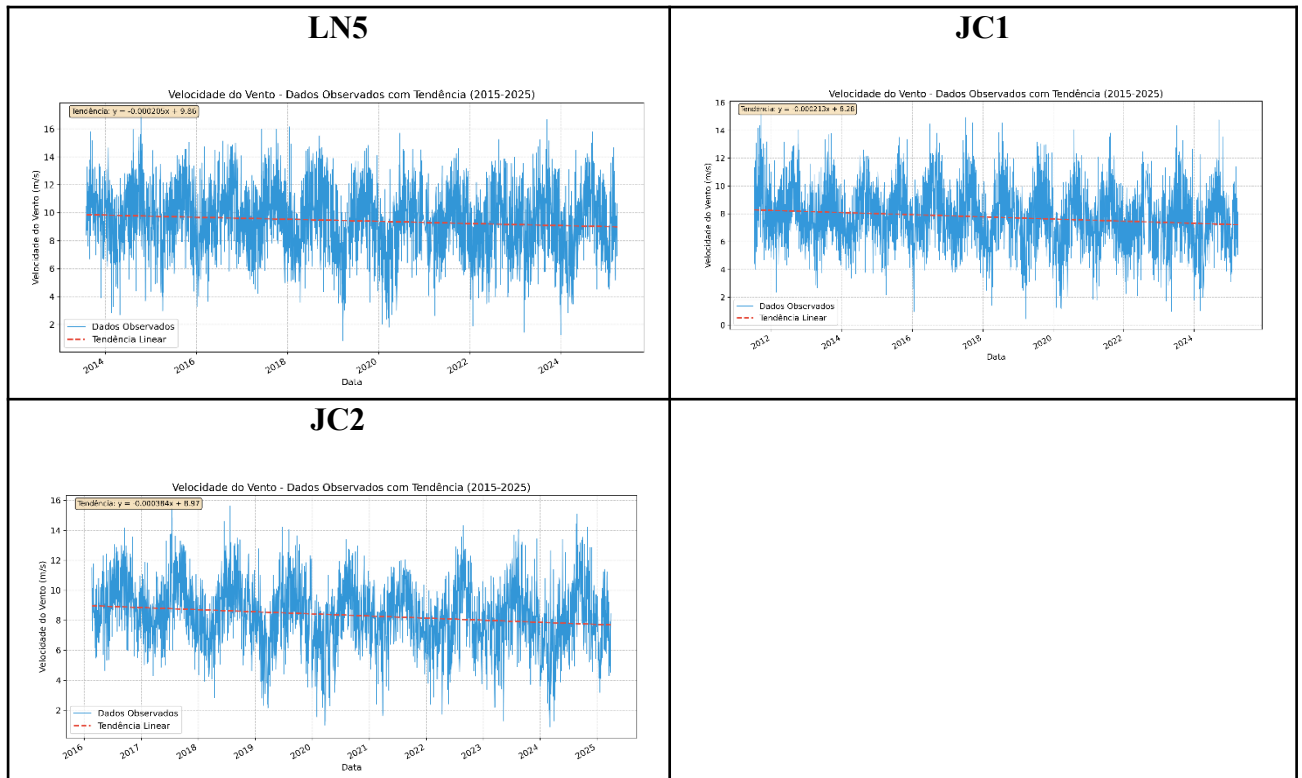




Fonte: autoria própria, 2025

Figura 3. Dados observados das estações selecionadas do Rio Grande do Norte





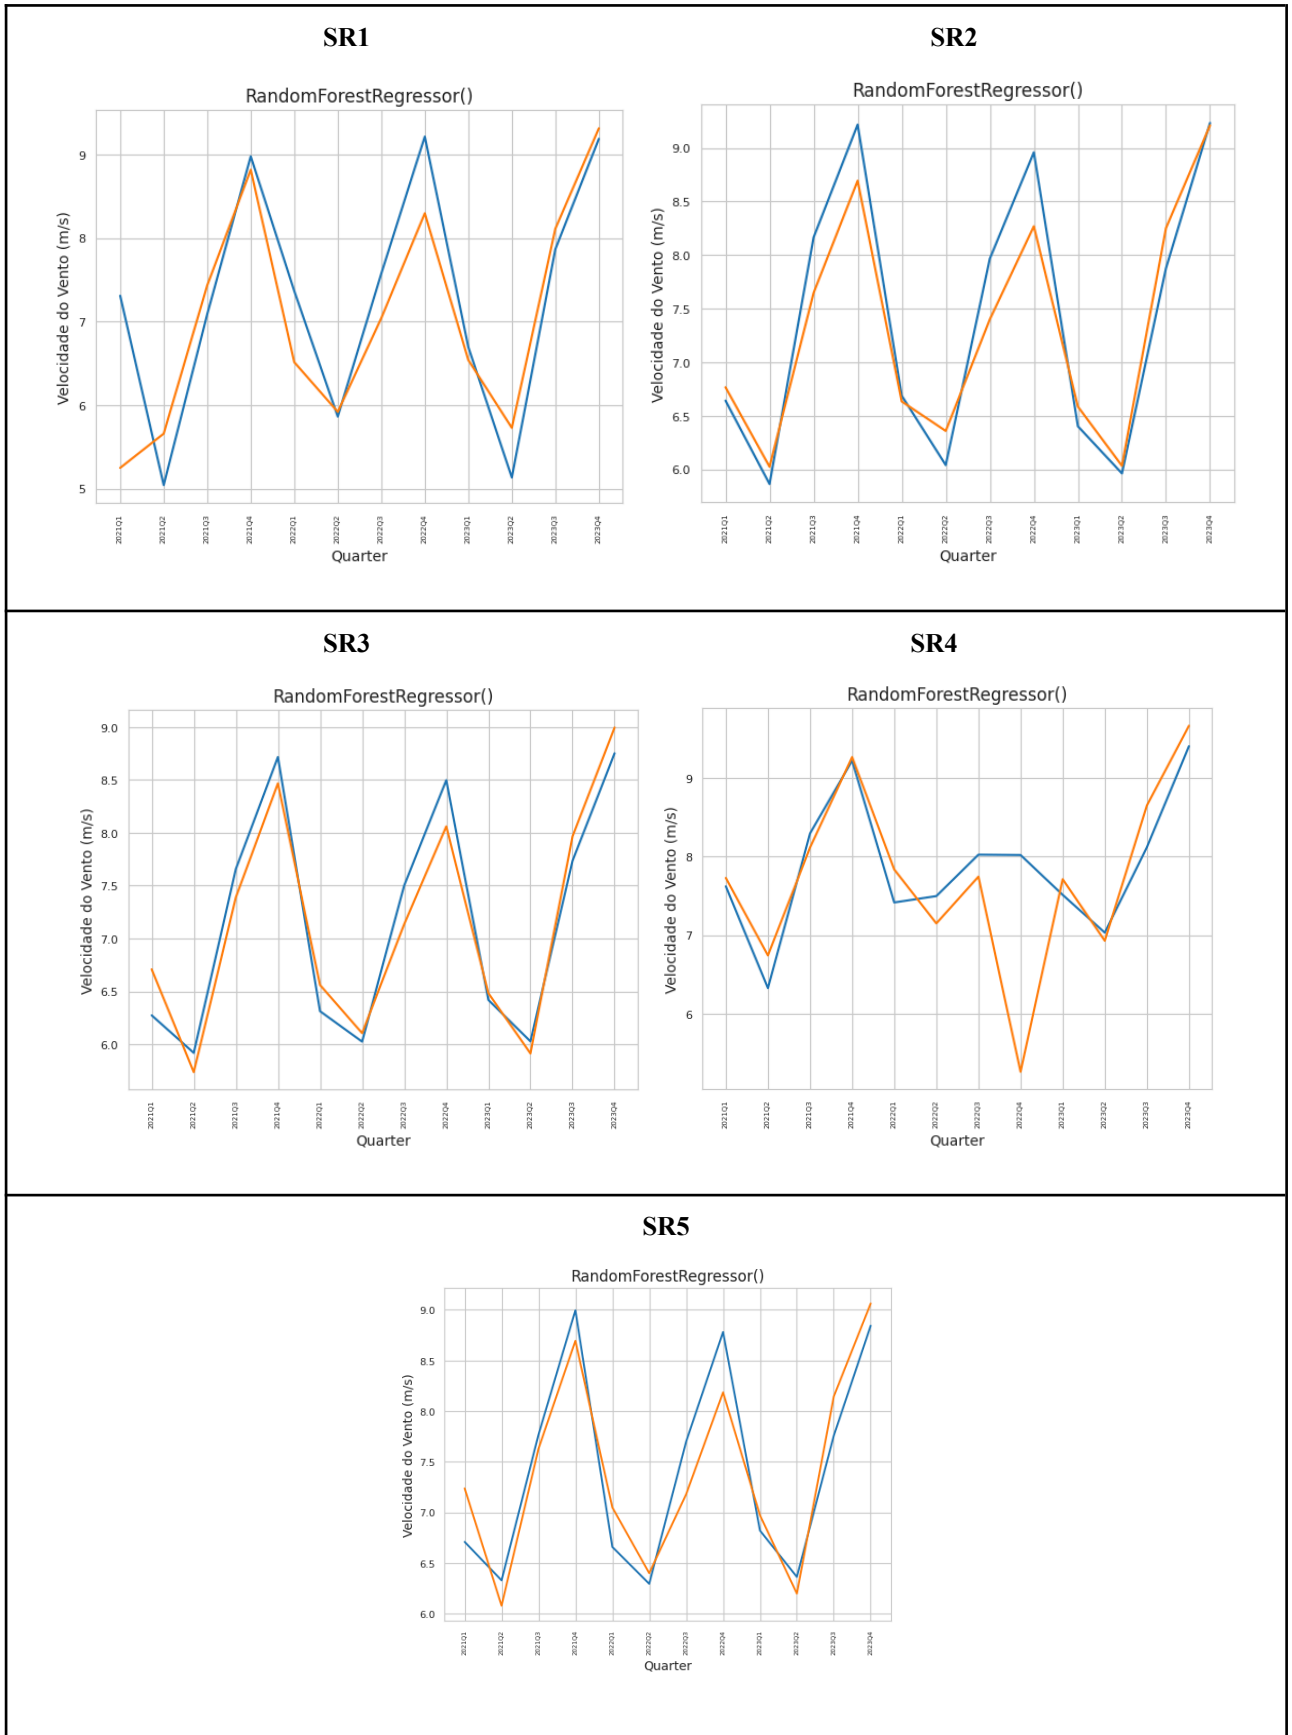
Fonte: autoria própria, 2025.

Ao analisar os dados observados, pode-se entender que as estações nos estados do Ceará e Rio Grande do Norte na última década apresentaram uma diminuição consistente na velocidade média do vento, análises observacionais focadas no Brasil confirmam a presença de sinais mistos regionais e identificam áreas do Nordeste com tendência de enfraquecimento em determinados períodos e estações, o que corrobora a detecção local aqui apresentada (LIMA, 2024). Apesar da diminuição, houve um aumento constante da produção de energia eólica ao longo da última década, como analisado pelo estudo Andrade, Melo, Lucena e Abrahão (2021), está mais relacionado com a melhora na tecnologia dos equipamentos, principalmente aerogeradores mais modernos com melhor índice de produtividade. Interessante ressaltar que esse tipo de contradição reforça a importância de entender as tendências das próximas décadas em relação à média das velocidades dos ventos. O aumento padrão da altura dos rotores partiu de 90 m para 150m na última década.

4.2 VALIDAÇÃO DOS MODELOS DE PREVISÃO

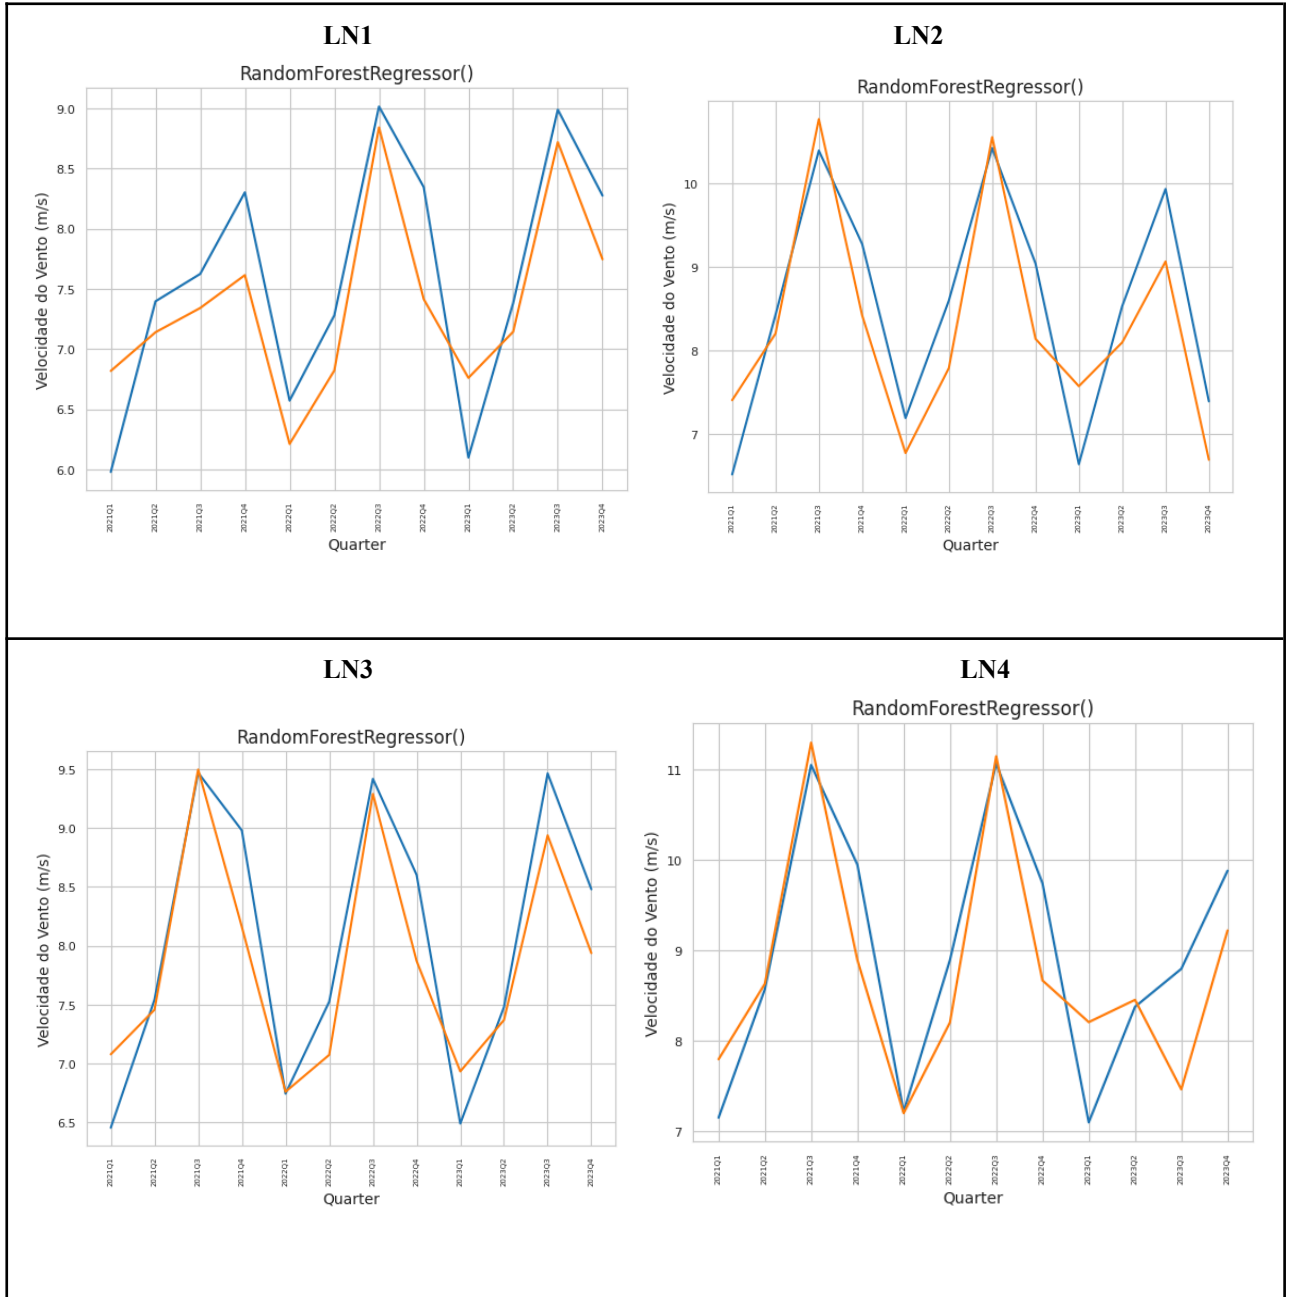
Os resultados das Tabela 5 e 6 são as validações obtidas a partir do teste das projeções do Random Forest, a linha em azul apresentada nos gráficos refere-se à predição realizada pelo modelo enquanto a laranja demonstra os dados dos ventos medidos de maneira real. Ressalta-se que nem todas as estações atenderam aos requisitos metodológicos propostos e, portanto, não tiveram resultados preditivos satisfatórios para a análise.

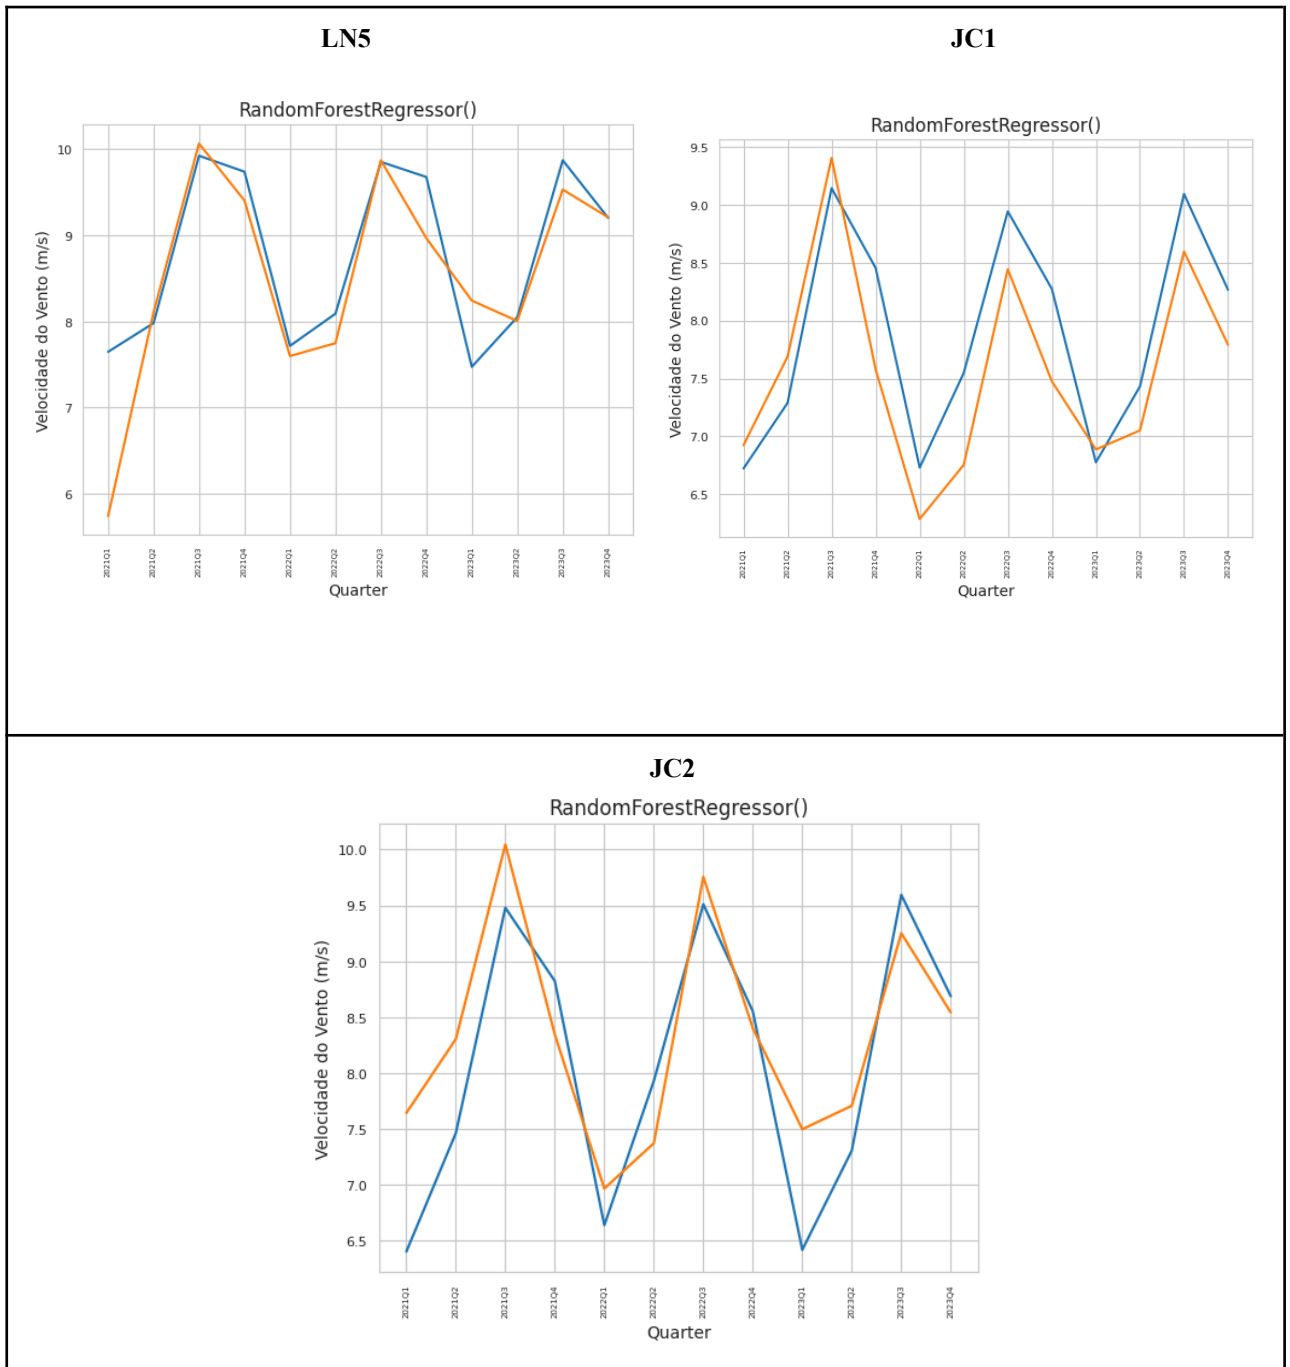
Figura 4. Validação do modelo Random Forest nas estações do estado do Ceará



Fonte: autoria própria, 2025.

Figura 5. Validação do modelo Random Forest nas estações do estado do Rio Grande do Norte





Fonte: autoria própria, 2025.

Na tabela 7 encontram-se as métricas de validação dos modelos regressores de inteligência artificial utilizados para a realização das projeções das tendências da velocidade do vento, nesse caso pode-se verificar os diferentes modelos e a acurácia de cada um a depender do seu método preditivo para o estudo em questão (GOODFELLOW, 2016).

Tabela 3. Análise do MAE e MAPE

Estado	Estação	Métrica	Decision Tree	Linear Regressor	KNN	Random Forest
Ceará	SR1	MAE	1,31	1,73	0,76	0,54
		MAPE	20,40%	26,00%	11,00%	8,70%
	SR2	MAE	0,48	2,04	0,6	0,31
		MAPE	6,60%	29,50%	7,90%	4,00%
	SR3	MAE	0,43	1,68	0,36	0,27
		MAPE	6,40%	25,20%	4,90%	3,80%
	SR4	MAE	0,85	1,93	0,83	0,46
		MAPE	12,20%	25,10%	11,50%	7,30%
	SR5	MAE	0,57	1,61	0,44	0,31
		MAPE	8,10%	22,40%	6,00%	4,10%
Rio Grande do Norte	JC1	MAE	0,45	0,8	0,42	0,47
		MAPE	6,00%	10,80%	5,70%	6,30%
	JC2	MAE	0,74	0,7	0,71	0,53
		MAPE	9,20%	8,50%	8,00%	6,70%
	LN1	MAE	0,73	0,63	0,48	0,48
		MAPE	9,10%	10,00%	6,50%	6,70%
	LN2	MAE	0,59	1,52	0,67	0,65
		MAPE	7,60%	19,10%	8,20%	8,10%
	LN3	MAE	0,78	0,7	0,36	0,35
		MAPE	9,80%	9,10%	7,60%	4,50%
	LN4	MAE	1,08	0,8	0,68	0,58
		MAPE	15,00%	9,60%	8,00%	6,90%
	LN5	MAE	1,06	1,87	0,54	0,4
		MAPE	13,80%	22,20%	7,30%	5,60%

Fonte: autoria própria, 2025.

Analisando os dados do desempenho dos modelos de regressão Decision Tree, Regressão Linear, KNN e Random Forest para projetar uma previsão das velocidades dos ventos nos dois estados apresentou uma variabilidade significativa na performance entre os diferentes modelos e estações (MAULUD; ABDULAZEEZ, 2020).

Na região de SR, o modelo Random Forest demonstrou um desempenho superior a todas as estações com menores valores de MAE e MAPE. Com um destaque maior em relação a estação SR1, onde se obteve MAE de 0,54 e MAPE de 8,7%, e em SR3, com MAE de 0,27 e MAPE de 3,8%. O resultado mostra que o Random Forest capturou de uma melhor maneira as variações médias da velocidade do vento, o que o tornou o método mais eficiente

para a região. O Decision Tree também demonstrou resultados satisfatórios, principalmente em SR5, com um MAE de 0,57 e MAPE de 8,10%, apesar de um leve aumento nos erros em outras estações analisadas. A Regressão Linear foi o pior modelo, com MAPE relativamente alto, como em SR4 (25,10%) e SR5 (22,40%), o que demonstra a maior incapacidade de modelar e projetar adequadamente a variabilidade do vento na região. O KNN, por sua vez, mostrou-se intermediário entre os modelos, com um MAPE de 11% em SR1 e de 6,00% em SR5, apresentando um desempenho inferior ao Random Forest e Decision Tree em termos de precisão e acurácia (GRÖMPING, 2009).

Em JC, o Random Forest demonstra novamente uma melhor acurácia e assertividade. Em JC1, apresentou MAE de 0,47 e MAPE de 6,3%, e em JC2, MAE de 0,53 e MAPE de 6,70%. Os resultados mostram que o modelo se demonstra robusto para capturar os padrões complexos e sazonais do vento, garantindo melhores previsões. A Decision Tree também apresentou um bom desempenho, com MAE de 0,45 e MAPE de 6,00% em JC1, foi pouco menos eficiente que o Random Forest. O KNN, com MAPE de 8,00% em JC2, e a Regressão Linear, com MAPE de 8,50% em JC2, ficaram de maneira bem abaixo do desempenho do Random Forest e Decision Tree, com erros percentuais mais elevados, o que sugere uma menor precisão nas previsões (SEGAL, 2004).

Em LN, os modelos variaram de forma ampla. O Random Forest se destacou como na maioria dos casos, em especial LN1, na qual houve o registro de 0,48 de MAE e 6,70% de MAPE, e em LN5, com MAE de 0,4 e MAPE de 5,60%. Apesar da assertividade, o modelo apresentou uma performance inferior em LN2, onde obteve MAPE de 8,10%, ainda que tenha sido o mais eficaz em comparação com os demais modelos. Novamente a regressão linear, mostrou-se pouco produtiva para fornecer boas previsões, especialmente em LN2, com MAPE de 19,10%, indicando seu baixo desempenho para esta estação. A Decision Tree e o KNN também tiveram dificuldades em LN2, com MAPE de 7,60% e 8,20%, respectivamente, confirmando que esta estação apresenta desafios adicionais para modelagem, devido possivelmente a um perfil de ventos menos previsível que as demais estações estudadas (GRÖMPING, 2009).

Em outras estações de LN, como LN3 e LN4, o Random Forest seguiu demonstrando sua robustez, com MAPE de 5,60% em LN5 e valores próximos em outras estações.


De forma geral, o Random Forest foi o modelo que mais acertou em todas as estações, ou seja, apresentou um melhor desempenho médio e com menores erros absolutos, com exceção de LN2, onde os modelos apresentaram maior dificuldade de capturar os padrões dos ventos da estação. A Decision Tree, embora tenha obtido resultados satisfatórios, mostrou-se


menos consistente que o Random Forest. A regressão linear e o KNN se mostraram pouco eficientes para a realização dos modelos, com valores de MAPE mais altos em praticamente todas as estações (SHARIFZADEH; SIKINIOTI-LOCK; SHAH, 2019).

Os resultados demonstram uma maior aderência para esse tipo de projeção com métodos baseados em árvores para realizar modelos de previsão de velocidade de vento, como o Random Forest e o Decision Tree que capturam de melhor maneira padrões complexos e não lineares de forma eficiente. Da mesma maneira, a regressão linear, acaba sendo um modelo mais simples, mostrou-se pouco capaz de identificar a complexidade e variação dos dados de vento, principalmente nas estações mais desafiadoras como LN2. O KNN, apesar de ter se adaptado melhor que a Regressão Linear em algumas estações, não se mostrou tão eficiente quanto os modelos baseados em árvore (SHARIFZADEH; SIKINIOTI-LOCK; SHAH, 2019).

4.3 PREVISÕES E TENDÊNCIAS DAS VELOCIDADES DOS VENTOS DOS ANOS DE 2024 E 2054

Figura 6. Projeção pelo Random Forest nas estações do estado do Ceará de 2024 até 2055

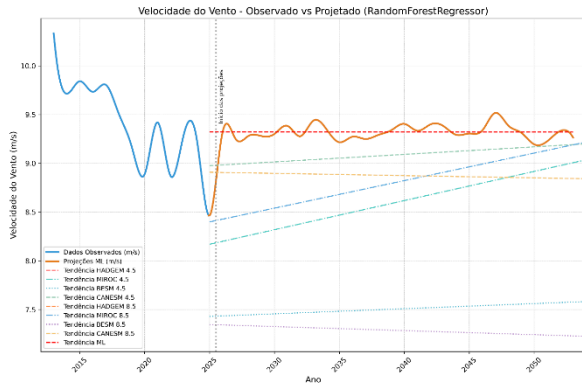




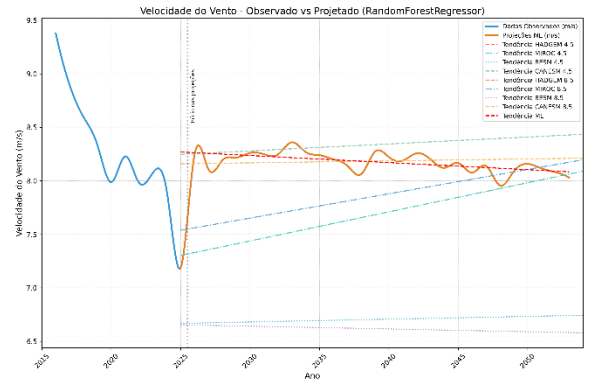
Fonte: autoria própria, 2025.

Figura 7. Projeção pelo Random Forest nas estações do estado do Rio Grande do Norte de 2025 até 2054


LN5




JC2




LN4




JC1




LN2



LN3





As projeções geradas pelos modelos Random Forest e Decision Tree, após ajuste de viés com os dados observados alimentados pelas saídas dos Eta-GCMs, demonstram uma tendência geral de um pequeno decréscimo nas velocidades médias dos ventos para décadas seguintes em ambos os estados. No geral, as reduções médias que foram projetadas variam de um decréscimo de 2% até 7%, com variações pequenas entre os modelos e os diferentes locais analisados. A tendência demonstra coerência em relação aos padrões identificados nas séries reais observadas, que também demonstraram um leve decréscimo na última década, especialmente quando olhamos para regiões mais interioranas dos estados.

Analisando a variação entre as décadas, nota-se que a tendência de redução da velocidade média dos ventos intensifica aos poucos ao longo das décadas projetadas. Quando se olha o primeiro período (2013-2025), período de teste, os valores projetados se mantêm próximos aos valores observados, o que evidencia uma estabilidade boa e também a reprodutibilidade dos modelos calibrados. Observando a década seguinte, 2026-2034, nota-se que a redução começa a aparecer, ainda que de forma branda e aparentemente natural. O enfraquecimento tende a se acentuar a partir das últimas décadas projetadas, quando diversos pontos de medição, especialmente no Rio Grande do Norte passaram a apresentar consideráveis quedas superiores 7%, considerando uma tendência contínua e gradual (SANTOS, 2013).

O comportamento sugere que as mudanças climáticas atuam sobre o regime eólico de

forma gradativa e cumulativa, como demonstram os estudos prévios que apresentam alterações graduais na maneira como o vento circula ao longo da superfície no século vigente (LIMA, 2024). Ademais, a permanência de uma tendência suave e estável, sem comportamentos bruscos e abruptos, reforça a coerência interna das projeções, o que demonstra que não existem sinais de variação forçada ou descontinuidade estatística do período estudado.

Ao analisar os modelos climáticos aninhados ao Eta demonstra as divergências relevantes na magnitude e tendência das projeções, mesmo que o comportamento em sua maior parte se mostre coerente. O HadGEM2-ES (Eta–HadGEM) e o CanESM2 (Eta–CanESM) projetam pequenos aumentos e estabilização das velocidades médias, acentuadas quando se analisa as primeiras décadas. Enquanto que o BESM (Eta–BESM) e o MIROC5 (Eta–MIROC) acompanham de forma mais coerente os comportamentos observados de forma empírica nas estações sendo atribuída às diferenças nas parametrizações de turbulência e na representação das circulações de grande escala que controlam os ventos alísios sobre o Nordeste brasileiro (CHOU *et al.*, 2014).

A média das projeções do ensemble Eta–GCMs sugere uma tendência de leve aumento ou estabilização do vento até a metade do século, mas as reduções previstas pelos modelos Random Forest e Decision Tree, ajustados com dados observacionais, indicam que o sinal local tende ao enfraquecimento, sobretudo nas áreas continentais. Essa diferença de comportamento entre o ensemble regional e os modelos estatísticos reforça a importância do downscaling e da calibração local, já que os Eta–GCMs, mesmo com resolução aprimorada, ainda suavizam características topográficas e efeitos costeiros essenciais para a dinâmica do vento em escala local (BALLARIN *et al.*, 2023; FREIRE *et al.*, 2022).

O Ceará, apresentou um regime eólico relativamente estável ao longo das décadas, com leves reduções distribuídas homogeneamente entre as estações. SR2 e SR4, situadas em locais mais elevados em relação ao nível do mar e com maior influência orográfica, apresentam reduções discretas, indicando que o local apresenta uma maior resiliência em relação ao regime eólico. SR5, que está relativamente mais próxima a costa do estado, mostra oscilações maiores, embora sem tender negativamente de forma acentuada. Esse comportamento como um todo nas estações situadas no Ceará se caracterizou por uma maior estabilização dos regimes dos ventos, o que é compatível com o papel dominante dos ventos alísios e menor variação interanual do estado (CAMELO, 2008).

Em contraste, o Rio Grande do Norte apresenta variações mais expressivas e espacialmente heterogêneas, com algumas estações evidenciando quedas mais acentuadas, especialmente nas áreas interiores. As estações LN1 e JC1, destacam-se com as reduções mais fortes, superando 6% nas projeções de longo prazo, tanto nos modelos Random Forest quanto Decision Tree. Por outro lado, a estação LN2, apresenta tendência menos pronunciada e maior variabilidade interdecadal. Esse padrão é consistente com estudos que apontam maior sensibilidade do interior potiguar às mudanças climáticas. (PES *et al.*, 2017; ANJOS *et al.*, 2020).

Analisando integralmente, ambos os estados apresentam reduções leves nas velocidades médias dos ventos, na sua imensa maioria brandas, demonstram que a região permanece favorável a geração da energia eólica de longo prazo. O enfraquecimento gradual é espacialmente concentrado nas áreas continentais mais localizadas ao interior dos estados. Enquanto que as áreas mais estáveis são geralmente na proximidade das zonas costeiras. Essa variação é mais aparente nas regiões em existem fortes influências dos processos locais o que reforça grande importância de trabalhar com mais de uma fonte de projeção, e a busca pela combinação de mais modelos de simulação para as abordagens estatísticas de machine learning, o que garante maior robustez e assertividade nas análises (GURGEL *et al.*, 2024; MARTINEZ; IGLESIAS, 2024).

As reduções projetadas, mesmo que pequenas, demandam atenção da sociedade principalmente na formulação de políticas públicas de estratégia e planejamento energético. Logo, recomenda-se que ocorra uma adoção de incentivos a produção de tecnologia que aumente a eficiência da produção de energia eólica através de novos equipamentos que performem de melhor maneira sob ventos moderados. O aumento da participação da energia solar também se torna crucial para o aumento da robustez do planejamento energético nacional, tornando-o mais adaptativo e com base em faixas grandes de incerteza. Essas medidas permitirão mitigar os impactos potenciais da redução dos ventos e assegurar a continuidade da expansão da matriz renovável.

5 CONCLUSÕES

A integração de dados observacionais, modelagem estatística e saídas de modelos climáticos regionais Eta-GCMs sugere que o padrão de ventos sobre o Nordeste brasileiro deve declinar brandamente nas próximas décadas, com variações no espaço entre os estados do Ceará e Rio Grande do Norte. A constatação dessa tendência, tanto nas séries históricas

quanto nas previsões dos modelos Random Forest e Decision Tree, é consistente com a literatura recente, que aponta para indícios de alterações climáticas, tanto de diminuição quanto de intensificação dos efeitos, em várias regiões do Brasil e do mundo (LIMA, 2024; ZENG *et al.*, 2019).

As diferenças entre os modelos climáticos acoplados ao Eta também se mostraram significativas. O Eta–HadGEM2-ES e o Eta–CanESM2 projetaram pequenos aumentos ou uma maior estabilidade nas velocidades médias, enquanto o Eta–BESM e o Eta–MIROC5 indicaram reduções mais consistentes, aproximando-se das projeções obtidas pelos modelos estatísticos. As diferenças entre os modelos demonstram que as análises possuem incertezas que são relevantes na análise o que reforça a necessidade de um refinamento estatístico para ajudar a capturar as particularidades inerentes de cada regime de vento. Os resultados reforçam que modelar de forma integral, combinando Eta-GCMs com métodos de aprendizado de máquina, representa um caminho confiável para avaliar impactos climáticos.

Do ponto de vista energético, o leve enfraquecimento previsto não compromete o potencial eólico da região, mas reforça a importância de um planejamento energético flexível e bem pensado, que considere margens de segurança e estratégias tecnológicas voltadas à eficiência. Por isso, recomenda-se o uso de turbinas ajustadas para operar bem em ventos moderados e também fortalecer a integração entre as fontes eólica e solar, já que a combinação dessas energias apresenta benefícios sazonais bastante reconhecidos no Nordeste (SOUZA *et al.*, 2023).

Além de implicar diretamente na geração da energia eólica, os resultados obtidos na pesquisa reforçam que o regime eólico dos dois estados é muito importante principalmente no avanço da cadeia do hidrogênio verde. Apesar das leves diminuições apresentadas, as condições climáticas permanecem extremamente favoráveis à produção da eletricidade renovável. O Ceará, com sua estabilidade eólica e boa infraestrutura de portos, avança como grande polo exportador, enquanto o Rio Grande do Norte, já possui imensa base instalada e grande potencial de expansão rumo a seu interior, tem um imenso papel na diversificação e no abastecimento interno e comércio internacional de energia. Assim, os cenários futuros indicam que o Nordeste brasileiro continuará sendo um forte contribuidor global de geração renovável e produção de hidrogênio sustentável, integrando políticas de mitigação climática e desenvolvimento industrial.

REFERÊNCIAS

- ANDRADE, A. R. et al. **Wind speed trends and the potential of electricity generation at new wind power plants in Northeast Brazil.** *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 43, n. 4, p. 1–11, 2021.
- ANJOS, M. et al. **Sea Breeze Front and Outdoor Thermal Comfort during Summer in Northeastern Brazil.** *Atmosphere*, v. 11, art. 1013, 2020.
- BALLARIN, A. S. et al. **CLIMBra – Climate Change Dataset for Brazil.** *Scientific Data*, v. 10, art. 47, 2023.
- BISHOP, C. M.; NASRABADI, N. M. **Pattern Recognition and Machine Learning.** New York: Springer, 2006.
- CAMELO, H. N. et al. **Análise estatística da velocidade de vento do estado do Ceará.** *Revista Tecnologia*, v. 29, n. 2, p. 211–223, 2008.
- CCEE – CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Relatório de Geração Eólica 2023.** São Paulo, 2023.
- CEPEL – CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. **Atlas Eólico Brasileiro.** Rio de Janeiro: Eletrobras, 2000.
- CHEN, L. et al. **Machine Learning Methods in Weather and Climate Applications: A Survey.** *Applied Sciences*, v. 13, n. 21, p. 12019, 2023.
- CHOU, S. C. et al. **Assessment of climate change over South America under RCP 4.5 and 8.5 downscaling scenarios.** *American Journal of Climate Change*, v. 3, n. 5, p. 512–527, 2014.
- DUEBEN, P. D.; BAUER, P. **Challenges and design choices for global weather and climate models based on machine learning.** *Geoscientific Model Development*, v. 11, p. 3999–4009, 2018.
- EPE – EMPRESA DE PESQUISA ENERGÉTICA. **Balço Energético Nacional 2025: Ano-base 2024.** Brasília: MME/EPE, 2025.
- FREIRE, J. L. M. et al. **Assessing the contribution of dynamical downscaling to austral autumn Northeast Brazil seasonal precipitation prediction performance.** *Climate Services*, v. 27, art. 100321, 2022.
- GELLER, H. S. et al. **Policies for advancing energy efficiency and renewable energy use in Brazil.** *Energy Policy*, v. 32, n. 12, p. 1437–1450, 2004.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning.** Cambridge: MIT Press, 2016.
- GRÖMPING, U. **Variable importance assessment in regression: linear regression versus random forest.** *The American Statistician*, v. 63, n. 4, p. 308–319, 2009.
- GURGEL, A. R. C. et al. **Wind power density in areas of Northeastern Brazil from**

Regional Climate Models for a recent past. *PLoS ONE*, v. 19, n. 7, e0307641, 2024.

HUA, W. et al. **Assessing climatic impacts of future land use and land cover change projected with the CanESM2 model.** *International Journal of Climatology*, v. 35, n. 12, p. 3661–3675, 2014.

IPCC. **Climate Change 2013: The Physical Science Basis.** Cambridge: Cambridge University Press, 2013.

IPCC. **Climate Change 2021: The Physical Science Basis.** Cambridge: Cambridge University Press, 2021.

JUÁREZ, A. A. et al. **Development of the wind power in Brazil: Political, social and technical issues.** *Renewable and Sustainable Energy Reviews*, v. 39, p. 828–834, 2014.

JUNG, C.; SCHINDLER, D. **A review of recent studies on wind resource projections under climate change.** *Renewable and Sustainable Energy Reviews*, v. 165, p. 112596, 2022.

JUNG, J.; BROADWATER, R. P. **Current status and future advances for wind speed and power forecasting.** *Renewable and Sustainable Energy Reviews*, v. 31, p. 762–777, 2014.

LARA-FANEGO, V. et al. **Evaluation of the performance of several short-term wind power forecasting models.** *Renewable Energy*, v. 83, p. 703–709, 2016.

LIMA, G. C. **Evolution of wind speed observed in Brazil between 1961 and 2020.** *International Journal of Climatology*, 2024.

LUCENA, A. F. P. et al. **The vulnerability of renewable energy to climate change in Brazil.** *Energy Policy*, v. 37, n. 3, p. 879–889, 2009.

LYRA, A. et al. **Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution.** *Theoretical and Applied Climatology*, v. 132, p. 663–682, 2017.

MARTINEZ, A.; IGLESIAS, G. **Global wind energy resources decline under climate change.** *Energy*, v. 288, art. 129765, 2024.

MITCHELL, T. M. **Machine Learning.** New York: McGraw-Hill, 1997.

PAO, H.-T.; FU, H.-C. **Renewable energy, non-renewable energy and economic growth in Brazil.** *Renewable and Sustainable Energy Reviews*, v. 25, p. 381–392, 2013.

PES, M. P. et al. **Climate trends on the extreme winds in Brazil.** *Renewable Energy*, v. 109, p. 110–120, 2017.

PRYOR, S. C. et al. **Climate change impacts on wind energy: a review.** *Renewable and Sustainable Energy Reviews*, v. 134, p. 110301, 2020.

RASP, S.; PRITCHARD, M. S.; GENTINE, P. **Deep learning to represent subgrid processes in climate models.** *PNAS*, v. 115, n. 39, p. 9684–9689, 2018.

ROSE, S.; APT, J. **Quantifying hurricane risk to offshore wind turbines.** *PNAS*, v. 118, n.

22, e2101767118, 2012.

RUFFATO-FERREIRA, V. et al. **A foundation for the strategic long-term planning of the renewable energy sector in Brazil.** *Renewable and Sustainable Energy Reviews*, v. 72, p. 1124–1137, 2017.

SANTOS, A. T. S.; SILVA, C. M. S. **Seasonality, interannual variability, and linear tendency of wind speeds in Northeast Brazil from 1986 to 2011.** *The Scientific World Journal*, 2013.

SEGAL, M. R. **Machine learning benchmarks and random forest regression.** *WIREs Data Mining and Knowledge Discovery*, v. 4, n. 1, p. 175–190, 2004.

SHARIFZADEH, M.; SIKINIOTI-LOCK, A.; SHAH, N. **Machine-learning methods for integrated renewable power generation.** *Renewable and Sustainable Energy Reviews*, v. 108, p. 513–538, 2019.

SIMAS, M.; PACCA, S. **Assessing employment in renewable energy technologies: a case study for wind power in Brazil.** *Renewable and Sustainable Energy Reviews*, v. 31, p. 83–90, 2014.

TSAI, W.-C. et al. **A Review of Modern Wind Power Generation Forecasting Technologies.** *Sustainability*, v. 15, art. 10757, 2023.

WATANABE, M. et al. **Improved climate simulation by MIROC5.** *Journal of Climate*, v. 23, p. 6312–6335, 2010.

XIONG, X. et al. **A Short-Term Wind Power Forecast Method via XGBoost.** *Frontiers in Energy Research*, v. 10, 2022.

ZENG, Z. et al. **A reversal in global terrestrial stilling and its implications for wind energy production.** *Nature Climate Change*, v. 9, p. 979–985, 2019.