



Rafael Araújo Couto

**Modelos de Simulação Estocástica de Cenários
de Velocidade do Vento Correlacionados com
Incorporação de Variáveis Climáticas**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia de Produção do Departamento de Engenharia Industrial da PUC-Rio.

Orientadora: Prof. Paula Medina Maçaira Louro
Co-orientador: Prof. Fernando Luiz Cyrino Oliveira

Rio de Janeiro
agosto de 2024



Rafael Araújo Couto

**Modelos de Simulação Estocástica de Cenários
de Velocidade do Vento Correlacionados com
Incorporação de Variáveis Climáticas**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia de Produção do Departamento de Engenharia Industrial da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Prof. Paula Medina Maçaira Louro

Orientadora

Departamento de Engenharia Industrial – PUC-Rio

Prof. Fernando Luiz Cyrino Oliveira

Co-orientador

Departamento de Engenharia Industrial – PUC-Rio

Prof. José Francisco Pessanha

Universidade do Estado do Rio de Janeiro – UERJ

Dr. Joaquim Dias Garcia

Power Systems Research – PSR

Rio de Janeiro, 19 de agosto de 2024

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientadora.

Rafael Araújo Couto

Graduou-se em Estatística pela Universidade Federal Fluminense em 2022. Durante o Mestrado atou em um projeto de P&D para o mercado de energia elétrica.

Ficha Catalográfica

Couto, Rafael Araújo

Modelos de Simulação Estocástica de Cenários de Velocidade do Vento Correlacionados com Incorporação de Variáveis Climáticas / Rafael Araújo Couto; orientadora: Paula Medina Maçaira Louro; co-orientador: Fernando Luiz Cyrino Oliveira. - 2024.

65 f. : il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2024.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Velocidade do Vento;. 3. PARX;. 4. Covariância;. 5. ENSO. I. Louro, Paula Medina Maçaira. II. Cyrino Oliveira, Fernando Luiz. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Agradecimentos

Primeiramente agradecer aos meus pais Elizabeth e Fabio, ao meu irmão Marcelo e toda a minha família, pelo apoio, suporte e compreensão de sempre, durante cada passo que me levou até esse momento.

Agradecer também a todos meus amigos que contribuíram de diversas maneiras durante esses dois anos, em especial a Tuany e Gustavo que estiveram comigo do primeiro dia ao último.

Por fim agradecer a minha orientadora Paula Maçaira e co-orientador Fernando Cyrino, que me auxiliaram em todo o trabalho e contribuíram com o meu progresso.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Couto, Rafael Araújo; Louro, Paula Medina Maçaira; Cyrino Oliveira, Fernando Luiz. **Modelos de Simulação Estocástica de Cenários de Velocidade do Vento Correlacionados com Incorporação de Variáveis Climáticas**. Rio de Janeiro, 2024. 65p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

A energia eólica tem crescido de forma estável no Brasil nos últimos anos. Para impulsioná-la, é crucial considerar as mudanças climáticas, já que sua geração é altamente influenciada pelo clima. Por isso, é fundamental incorporar variáveis climáticas externas na modelagem das séries eólicas, contribuindo para reduzir as incertezas. Os Modelos Periódicos Autorregressivos com Variáveis Exógenas (PARX) representam uma abordagem viável para cumprir esse propósito, incluindo a variável exógena ENSO. No presente estudo, realizou-se a modelagem das séries de velocidade do vento nos estados do Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Rio Grande do Sul e Santa Catarina. Nesse sentido, foi considerada a covariância entre esses estados em cada região brasileira para avaliar a correlação espacial entre eles, criando a modelagem PARX-Cov. Além disso, a correlação entre os indicadores do fenômeno ENSO também foi considerada para viabilizar a previsão *out-of-sample* das variáveis climáticas, essa utilizada para a simulação de cenários de velocidade de vento. Ao comparar a modelagem do PARX e PARX-Cov, com o modelo vigente no setor elétrico brasileiro, observou-se um desempenho superior nos modelos propostos para a simulação de realizações futuras das séries de velocidade do vento. O modelo PARX-Cov com o índice ONI Acumulado é o mais adequado para Pernambuco, Rio Grande do Sul e Santa Catarina. O PARX-Cov com o índice SOI é mais apropriado para o Rio Grande do Norte. Para Alagoas e Sergipe, o PARX com o índice ONI Acumulado é o mais indicado, enquanto o PARX com Niño 4 Acumulado é melhor para a Paraíba.

Palavras-chave

Velocidade do Vento; PARX; Covariância; ENSO

Abstract

Couto, Rafael Araújo; Louro, Paula Medina Maçaira (Advisor); Cyrino Oliveira, Fernando Luiz (Co-Advisor). **Stochastic Simulation Models of Correlated Wind Speed Scenarios with Incorporation of Climate Variables**. Rio de Janeiro, 2024. 65p. Dissertação de Mestrado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

Wind energy has been steadily growing in Brazil in recent years. To boost its growth, it is crucial to consider climate change, as wind energy generation is highly influenced by the weather. Therefore, it is essential to incorporate external climatic variables into the modeling of wind series, helping to reduce uncertainties. Periodic Autoregressive Models with Exogenous Variables (PARX) represent a viable approach to achieve this, including the ENSO exogenous variable. In the present study, wind speed series were modeled in the states of Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Rio Grande do Sul, and Santa Catarina. In this context, the covariance between these states in each Brazilian region was considered to assess the spatial correlation among them, creating the PARX-Cov modeling. Furthermore, the correlation between ENSO phenomenon indicators was also considered to enable out-of-sample forecasting of climatic variables, used for simulating wind speed scenarios. When comparing the PARX and PARX-Cov modeling with the current model in the Brazilian electric sector, the proposed models showed superior performance in simulating future wind speed series. The PARX-Cov model with the Accumulated ONI index is most suitable for Pernambuco, Rio Grande do Sul, and Santa Catarina. The PARX-Cov model with the SOI index is more appropriate for Rio Grande do Norte. For Alagoas and Sergipe, the PARX model with the Accumulated ONI index is the most recommended, while the PARX model with Accumulated Niño 4 is better for Paraíba.

Keywords

Wind Speed; PARX; Covariance; ENSO

Sumário

1	Introdução	12
1.1	Motivação	12
1.2	Objetivos	14
1.3	Organização	15
2	Revisão da Literatura	16
3	Metodologia	19
3.1	Pré-Processamento	19
3.2	Modelagem	21
3.2.1	Modelo Periódico Autorregressivo (PAR)	21
3.2.2	Modelo Periódico Autorregressivo com Variáveis Exógenas (PARX)	22
3.2.3	Covariância (PAR-Cov & PARX-Cov)	24
3.3	Pós-Processamento	26
3.3.1	Métricas de Desempenho	26
3.3.2	Geração de Cenários Sintéticos de Velocidade do Vento	27
4	Análise Descritiva dos Dados	30
4.1	Velocidade do Vento	30
4.2	ENSO	33
4.2.1	O Fenômeno ENSO	33
4.2.2	Índices	35
4.2.2.1	Histórico	36
4.2.2.2	Previsão	38
4.3	Relação entre Velocidade do Vento e ENSO	41
5	Resultados	44
6	Conclusão	50
7	Referências Bibliográficas	53
A	Apêndice - Ajuste ENSO 2023	61
B	Apêndice - Métricas MAE e R^2	64

Lista de Figuras

Figura 3.1	Estados selecionados em verde do Nordeste e em amarelo do Sul. Fonte: Elaboração própria.	19
Figura 4.1	Séries Temporais de Velocidade do Vento por Estado. Fonte: Elaborado pelo autor.	31
Figura 4.2	Função de Autocorrelação das Séries Temporais de Velocidade do Vento por Estado. Fonte: Elaborado pelo autor.	32
Figura 4.3	Circulação de Walker. Fonte: [73].	34
Figura 4.4	Localização do SOI e SOI Equatorial. Fonte: [76].	35
Figura 4.5	Localização do SST e ONI. Fonte: [76].	36
Figura 4.6	Séries Temporais das Anomalias dos Índices Históricos do ENSO. Fonte: Elaborado pelo autor.	37
Figura 4.7	Séries Temporais das Anomalias Acumuladas dos Índices Históricos do ENSO. Fonte: Elaborado pelo autor.	38
Figura 4.8	Previsões das Probabilidades de fases e de Anomalias do ENSO - 2024. Fonte: [52].	39
Figura 4.9	Gráficos de Dispersão dos Valores Observados x Ajustados dos Índices - 2024. Fonte: Elaborado pelo autor.	40
Figura 4.10	Previsão dos Índices ENSO - 2024. Fonte: Elaborado pelo autor.	41
Figura 4.11	Comportamento da Velocidade do Vento por Evento ENSO. Fonte: Elaboração própria.	43
Figura 5.1	RMSE obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.	46
Figura 5.2	Velocidade do vento observada (preto), e previsões obtidas via modelo PAR (vermelho) e o melhor modelo PARX ou PARX-Cov (azul escuro), sobre a janela 6. Fonte: Elaborado pelo autor.	48
Figura 5.3	Cenários (azul claro), e previsões obtidas pelo melhor modelo PARX ou PARX-Cov (azul escuro) e o modelo PAR (vermelho), sobre a janela 7. Fonte: Elaborado pelo autor.	49
Figura A.1	Previsões da Probabilidades de fases e de Anomalias do ENSO - 2023. Fonte: [52].	61
Figura A.2	Gráficos de Dispersão dos Valores Observados x Ajustados dos Índices - 2023. Fonte: Elaborado pelo autor.	62
Figura A.3	Previsão dos Índices ENSO - 2023. Fonte: Elaborado pelo autor.	63

Figura B.1 MAE obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.

64

Figura B.2 R^2 obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.

65

Lista de Tabelas

Tabela 4.1	Estatísticas Descritivas das Séries de Velocidade do Vento por Estado. Fonte: Elaborado pelo autor.	32
Tabela 4.2	P-valor dos Testes de Estacionariedade.	33
Tabela 4.3	Ajuste dos Índices do ENSO ao ONI - 2024. Fonte: Elaborado pelo autor.	40
Tabela 4.4	P-Valor e Respostas do Teste de Kruskal-Wallis. Fonte: Elaborado pelo autor.	42
Tabela 5.1	Janelas de Ajuste e Previsão. Fonte: Elaborado pelo autor.	44
Tabela 5.2	Resumo das variáveis a serem utilizadas.	45
Tabela 5.3	Melhores modelos nas janelas 2 a 5 para as métricas RMSE, MAE e R^2 . Fonte: Elaborado pelo autor.	47
Tabela 5.4	Resumo dos modelos mais escolhidos como melhores.	47
Tabela 5.5	Melhor modelo com um índice ENSO selecionado para cada Estado.	48
Tabela A.1	Ajuste dos Índices do ENSO ao ONI - 2023. Fonte: Elaborado pelo autor.	62

Lista de Abreviaturas

ACF	–	Função de Autocorrelação
ADF	–	<i>Augmented Dickey-Fuller</i>
AIC	–	Critério de Informação de Akaike
AMO	–	Atlantic Multidecadal Oscillation
AR	–	Modelo Autorregressivo
AO	–	<i>Arctic Oscillation</i>
ARIMA	–	Modelo Autorregressivo Integrado de Médias Móveis
ARIMAX	–	Modelo Autorregressivo Integrado de Médias Móveis com Variáveis Exógenas
ARMA	–	Modelo Autorregressivo de Médias Móveis
ARX	–	Modelo Autorregressivo com Variáveis Exógenas
BIC	–	Critério de Informação Baiano
CPC	–	<i>Climate Prediction Center</i>
ENA	–	Energia Natural Afluente
ENSO	–	<i>El Niño-Southern Oscillation</i>
IRI	–	<i>International Research Institute</i>
LOACs	–	<i>Large-Scale Ocean-Atmosphere Circulations</i>
MAE	–	<i>Mean Absolute Error</i>
MQO	–	<i>Mínimos Quadrados Ordinários</i>
NAO	–	<i>North Atlantic Oscillation</i>
NOAA	–	<i>National Oceanic and Atmospheric Administration</i>
ONI	–	<i>Oscillation Niño Index</i>
ONS	–	Operador Nacional do Sistema
PAR	–	Modelo Periódico Autorregressivo
PARMA	–	Modelo Periódico Autorregressivo de Médias Móveis
PARX	–	Modelo Periódico Autorregressivo com Variáveis Exógenas
PeACF	–	Função de Autocorrelação Periódica
PePACF	–	Função de Autocorrelação Parcial Periódica
PDO	–	<i>Pacific Decadal Oscillation</i>
RMSE	–	<i>Root Mean Square Error</i>
SOI	–	<i>Southern Oscillation Index</i>
SST	–	<i>Sea Surface Temperature</i>
SVM	–	<i>Support Vector Machine</i>

1

Introdução

1.1

Motivação

Atualmente, a eletricidade no Brasil é produzida principalmente por fontes renováveis, que correspondem por mais de 80% do total da capacidade de geração de eletricidade, com destaque para as hidrelétricas, cuja proporção na matriz elétrica do país chega a mais de 65% [1]. No entanto, fontes térmicas ainda são necessárias para atender parte da demanda interna, principalmente em períodos de estiagem, que podem afetar os reservatórios hídricos, sendo necessário, para suprir essa carência, acionar as usinas termelétricas movidas a combustíveis fósseis em modo contínuo e em sua capacidade máxima [2]. Para suprir essa demanda de forma sustentável é importante ampliar outras fontes renováveis além da hídrica, como a eólica, que possui uma complementariedade com a fonte hídrica [3, 4].

A energia eólica é capaz de fornecer soluções energéticas adequadas e ecologicamente positivas para a geração de energia já que sua utilização elimina resíduos não desejados e prejudiciais à saúde, provenientes de outras fontes energéticas como o carvão [6]. O vento é considerado um recurso energético atraente porque é renovável, limpo, socialmente justificável e economicamente competitivo [5]. Outra contribuição da energia eólica é que ela também desempenha um papel importante na redução das emissões de gases de efeito estufa, atenuando assim o aquecimento global [7].

Nesse sentido, o Brasil é considerado um país altamente promissor na geração de energia eólica, pois há um grande crescimento da instalação de novas usinas eólicas nos últimos anos no Brasil, onde a capacidade instalada de geração eólica cresceu mais de 300%, isto é, saltou de 178 GW em 2010 para cerca de 734 GW em 2020 [9]. Segundo o Conselho Global de Energia Eólica [8], em 2021 o país se encontrava em 6º lugar no Ranking mundial de capacidade instalada de energia eólica. A pesquisa aponta que os ventos no território brasileiro apresentaram um fator de capacidade média de 42,7% em 2019, enquanto que o fator de capacidade média mundial é somente de aproximadamente 34%.

Para apoiar o planejamento, operação e monitoramento de sistemas elétricos complexos, como o brasileiro, é crucial enfrentar os desafios relacionados à modelagem e simulação dos processos estocásticos de geração de energia renovável, conforme destacado por Pinson [10]. Devido à incerteza inerente ao planejamento energético no Brasil, torna-se imperativo adotar uma modelagem

estocástica das séries de energia de forma eficiente. Ao garantir uma modelagem e simulação precisas, é possível fortalecer a robustez e a confiabilidade desses sistemas, proporcionando uma base sólida para as decisões tanto do setor público quanto do privado [11].

O processo vigente no setor elétrico brasileiro é realizado a partir de um modelo Periódico Autorregressivo (PAR) [12] para a geração integrada de séries sintéticas de velocidades de ventos correlacionadas às aflúências dos reservatórios das hidrelétricas, com base em Maceira et al. [3]. Entretanto, como este trabalho focará exclusivamente na velocidade do vento, será considerado o uso do modelo PAR aplicado à velocidade, ajustado com base nos parâmetros estimados do histórico correspondente. Embora essa abordagem altere parte do processo atualmente em uso, os cenários de velocidade do vento gerados neste estudo podem ser de interesse para as mesmas entidades do setor elétrico que atuam no NEWAVE. O modelo PAR assume que as séries eólicas são estacionárias, lineares e seguem uma distribuição Normal [13]. Além disso, é um modelo univariado, o que significa que não considera qualquer informação exógena que possa afetar os regimes de vento e, conseqüentemente, a produção de energia

Para maximizar o aproveitamento da energia eólica, é crucial considerar as atuais mudanças climáticas, uma vez que a geração de energia eólica é altamente influenciada pelo clima, cujas condições podem impactar na produção e na disponibilidade dos recursos eólicos no Brasil [14]. Estudos indicam que a inclusão de variáveis climáticas na modelagem das séries de velocidade do vento pode reduzir as incertezas [15, 16]. Embora as informações climáticas mais comumente utilizadas sejam pressão, temperatura e precipitação, o fenômeno *El Niño-Southern Oscillation* (ENSO) também surge como uma alternativa viável, dada sua forte relação com a velocidade do vento, conforme destacado por Couto et al. [17] e corroborado por diversos estudos tanto no Brasil [18, 19, 20], quanto globalmente [21, 22, 23]. Além disso, Maçaira [24] conduziu uma análise detalhada da relação entre o ENSO e outro recurso primário, a vazão, obtendo resultados promissores. De maneira similar, Treistman et al. [25] realizou um estudo no qual a precipitação foi relacionada ao fenômeno ENSO, também resultando em achados favoráveis.

Junto à isso, Maçaira et al. [26] realizaram uma revisão sistemática da literatura e identificaram que modelos de regressão, redes neurais, modelos autorregressivo integrado de médias móveis com variáveis exógenas (ARIMAX), *support vector machine* (SVM) e modelos estruturais estão entre os mais utilizados em estudos que incorporam variáveis exógenas. Em um estudo mais recente, Pessanha et al. exploraram o uso de modelos dinâmicos aliados a uma

abordagem Bayesiana para a geração de séries de velocidade do vento [27]. Este trabalho propõe uma alternativa: uma extensão do modelo vigente, que já obteve resultados promissores em estudos anteriores de Maçaira [24] para previsão de vazão, utilizando modelos Periódicos Autorregressivos com Variáveis Exógenas (PARX). Além disso, esta abordagem também é uma extensão dos modelos ARX, que se mostraram prósperos no estudo de Duran et. al [28]. Portanto, a expectativa é que a abordagem PARX ofereça uma capacidade de modelagem e simulação superior à atualmente empregada no setor elétrico para séries de velocidade de vento.

Por fim, para aprimorar a relação e compreensão dos dados de velocidade do vento, a covariância será considerada entre as velocidades do vento nos estados de cada região brasileira [29, 30, 31]. Nesse sentido, [28] também realizou uma análise comparativa de parques eólicos, demonstrando que a previsão melhora pela agregação dos parques. Além disso, Iung et al. realizaram uma revisão sistemática da literatura, destacando a ampla variedade de métodos utilizados para quantificar a dependência temporal na modelagem de energias renováveis [32].

1.2

Objetivos

O objetivo principal deste trabalho é desenvolver uma abordagem metodológica para a geração de séries de velocidade do vento de áreas com alta geração eólica no Brasil que incorpore variáveis climáticas para aprimorar a modelagem e simulação. Especificamente, os objetivos secundários são:

- i) Adicionar uma variável exógena ao modelo PAR para séries de velocidade do vento, utilizando o modelo Periódico Autorregressivo com Variáveis Exógenas (PARX);
- ii) Considerar a covariância entre os regimes de vento dos estados em cada região brasileira para aprimorar a precisão da modelagem e simulação;
- iii) Consideração da correlação entre os indicadores do fenômeno ENSO para viabilizar a previsão *out-of-sample* das variáveis climáticas;
- iv) Utilização de previsão *out-of-sample* de variáveis climáticas para simulação de cenários de velocidade de vento.

1.3**Organização**

Este trabalho está estruturado em seis capítulos, iniciando com esta introdução que aborda a motivação e estabelece os objetivos. O Capítulo 2 abrange a revisão bibliográfica. A metodologia aplicada é detalhada no Capítulo 3. Em seguida, no Capítulo 4, é realizada uma análise descritiva das variáveis eólicas e climáticas. O Capítulo 5 apresenta os resultados e suas implicações. Por fim, as conclusões desta pesquisa serão abordadas no Capítulo 6.

2

Revisão da Literatura

Neste capítulo será apresentada a revisão da literatura focada na inserção de variáveis climáticas, com destaque para o ENSO. Inicialmente os estudos abordarão o território brasileiro e em seguida, estudos ao redor do mundo também serão explorados.

Em relação aos trabalhos que consideram a influência de variáveis climáticas na velocidade de vento, no Brasil, destacam-se Corrêa et al. [18], que analisam o comportamento de séries temporais do Índice de Oscilação Sul no Nordeste do Brasil, na região do Centro de Lançamento de Alcântara, localizada no Maranhão. Os resultados mostraram que a série temporal da velocidade média mensal do vento na região está correlacionada com a variabilidade do Índice de Oscilação Sul. Assim mostrou-se a possibilidade de utilização de modelos autorregressivos para uma possível influência climática do *El Niño*-Oscilação Sul na força do vento no Maranhão.

Lima et al. [19] realizam uma análise estatística na região Nordeste do Brasil para quantificar o efeito do *El Niño* na geração eólica através do modelo *Generalized Autoregressive Score* (GAS). O GAS é aplicado às séries de velocidade do vento a partir da distribuição Gama. Os resultados do modelo mostraram que o *El Niño* tem influência no comportamento do vento, mesmo sendo de pequena magnitude.

Lopes et al. [20] verificam a Temperatura da Superfície do Mar (*Sea Surface Temperature*, SST) nos oceanos Pacífico e Atlântico Tropical, bem como os fenômenos *El Niño*, *La Niña* e o Dipolo do Atlântico em relação as condições de vento de superfície na Paraíba/Nordeste do Brasil e o impacto sobre a energia eólica. Nos eventos de *El Niño* foram verificadas as menores variações na velocidade do vento, enquanto nos casos de *La Niña* e Dipolo/Gradiente negativo foram verificadas as maiores variações na velocidade do vento.

de Souza et al. [33] analisam o comportamento de regimes de velocidade do vento na região do estado da Bahia, Nordeste do Brasil, em busca de correlações com fenômenos climáticos. Os resultados da análise da velocidade média horária do vento a partir dos dados medidos e simulados sugerem uma forte correlação com as oscilações do Atlântico e do Pacífico (*La Niña* e *El Niño*).

Cavalcanti et al. [34] avaliaram a variabilidade sazonal e interanual da velocidade do vento na região Nordeste do Brasil. Os resultados indicam que durante os anos de *El Niño* o vento é mais forte que a média (superando 45% no outono e até 25% na primavera), enquanto nos anos de *La Niña* é abaixo

da média em áreas com maior potencial eólico médio (40% no outono e até 30% na primavera).

Torres et al. [35] investigaram tendências da velocidade do vento de 47 estações meteorológicas do INMET, que foram agrupadas. Certos grupos apresentaram maiores médias anuais na variabilidade interanual da velocidade do vento. Esses picos observados foram atribuídos aos eventos *El Niño* e *La Niña*, que alteram o comportamento da circulação global dos ventos e influenciam a velocidade dos ventos na região.

Franchito et al. [36] estudam as relações entre a ressurgência costeira e os ventos locais em Cabo Frio (Brasil) usando Temperatura da Superfície do Mar, séries temporais de ventos de superfície e o ENSO. Os resultados mostram que as variações sazonais da SST e dos ventos locais estão intimamente relacionadas. Além disso, os maiores valores de SST ocorrem durante evento fortes de *El Niño* e os mais baixos ocorrem em evento moderados de *El Niño*.

Arpe et al. [21] mostram que na região do Mar Cáspio Sul (CS) existe uma intensa relação entre o nível do Mar Cáspio (CSL) e a velocidade do vento na região, sendo esta podendo ser induzida por uma teleconexão do *El Niño*. É demonstrado que o impacto do ENSO é muito mais forte do que o da Oscilação do Atlântico Norte (NAO), não apenas para a mudança do CSL, mas também para vários componentes-chave do orçamento hídrico do CS, como a vazão do rio Volga e a velocidade do vento.

Xu et al. [22] indicam que o ENSO tem um impacto significativo nos recursos eólicos *offshore* da China. Para eventos ENSO com diferentes intensidades, o impacto do ENSO nos recursos eólicos regionais varia com o tempo e o espaço. Em geral, o *El Niño* reduziu a energia eólica na maioria das regiões do Mar da China, exceto no Mar de Bohai e na Baía de Beibu, enquanto o *La Niña* fortaleceu os ventos na maioria das áreas, exceto no Mar de Bohai e no sul do Mar da China Meridional.

Coria et al. [23] avaliou o impacto do "*El Niño* Godzilla", um forte *El Niño*, no Golfo de Tehuantepec, região mexicana do Oceano Pacífico, no inverno de 2015-2016 em comparação com invernos anteriores. Os resultados mostraram que a velocidade do vento e a Temperatura da Superfície do Mar durante o inverno de 2015/2016 foram superiores às observadas durante os invernos de 2013/2014 e 2014/2015.

Enfield et al. [37] verificam que na região do Atlântico Norte, a variabilidade da Temperatura da Superfície do Mar está correlacionada com a variabilidade do ENSO. Uma análise dos campos de fluxo de superfície locais mostra que o aquecimento do Atlântico relacionado com o ENSO ocorre como resultado de reduções nas velocidades dos ventos, que por sua vez reduzem as

perdas de calor latente e sensível sobre a região em questão, bem como como resfriamento devido ao arrastamento.

Renken et al. [38] analisam mudanças abruptas na série temporal do Índice de Oscilação Sul (*Southern Oscillation Index*, SOI) para demonstrar que essas mudanças podem estar associadas a possível ocorrência de grandes eventos climáticos severos, como velocidades do vento extremas. Os resultados demonstram que mais de 70% dessas grandes ocorrências climáticas severas foram associadas a mudanças abruptas positivas e negativas no SOI diário.

Li et al. [39] analisam a velocidade do vento próximo à superfície na China e no Japão, junto a possíveis fenômenos climáticos que podem ser fatores de influência. Os resultados mostram que a velocidades do vento estavam intimamente associadas às circulações oceano-atmosfera em grande escala (*Large-Scale Ocean-Atmosphere Circulations*, LOACs). Em 77,4% das estações no leste da China mostra correlação significativa com o índice de monções de inverno do Leste Asiático, além disso, a variabilidade inter/multidecadal foi consideravelmente correlacionada com quatro LOACs, incluindo Oscilação do Ártico (*Arctic Oscillation*, AO), Oscilação do Atlântico Norte (*North Atlantic Oscillation*, NAO), Oscilação Decadal do Pacífico (*Pacific Decadal Oscillation*, PDO) e ENSO. A série temporal reconstruída por um modelo de regressão linear múltipla baseado nos cinco LOACs acima corresponde bem ao histórico da velocidade do vento. A variabilidade interanual da velocidade do vento foi significativamente correlacionada com AO e NAO, enquanto a correlação entre velocidade do vento e ENSO foi fraca.

Bastidas et al. [40] analisam as baixas velocidades do vento do Mar do Caribe colombiano e os resultados mostraram que os ventos da área de estudo apresentaram as menores velocidades de vento no curto, médio e longo prazo devido à influência das estações do ano, ao ENSO e à Oscilação Multidecadal do Atlântico (*Atlantic Multidecadal Oscillation*, AMO).

No geral, a maioria dos estudos identificou uma correlação entre os padrões eólicos e variáveis climáticas, especialmente associados ao fenômeno ENSO. Além disso, certas pesquisas aplicaram diferentes técnicas para modelar séries de velocidade do vento com base nas variáveis climáticas correlacionadas. No entanto, dois *gaps* foram identificados. Primeiramente, não foram encontrados estudos que investiguem a correlação e/ou influência de todos os índices ENSO nos estados brasileiros. Em segundo lugar, não foram encontradas pesquisas que explorem modelos periódicos ligados ao ENSO como uma variável exógena. Este trabalho busca endereçar esses *gaps* ao analisar diversos índices ENSO e aplicar o Modelo Periódico Autorregressivo com Variáveis Exógenas (PARX) para séries de velocidade do vento no Brasil.

3

Metodologia

Este capítulo se inicia com a apresentação dos dados e seus tratamentos, seguindo para as diferentes modelagens aqui trabalhadas e fechando com as métricas de avaliação e o processo da geração de cenários sintéticos de velocidade de vento.

3.1

Pré-Processamento

Para as análises conduzidas neste trabalho, foram selecionados cinco estados da região Nordeste: Rio Grande do Norte (RN), Paraíba (PB), Pernambuco (PE), Alagoas (AL) e Sergipe (SE) e dois estados da região Sul: Rio Grande do Sul (RS) e Santa Catarina (SC), que possuem áreas costeiras com alta geração eólica no Brasil, conforme destacado na Figura 3.1 em verde, os estados do Nordeste e em amarelo, os estados do Sul. Vale ressaltar que os demais estados do Nordeste, principalmente, Ceará e Bahia, apresentavam potencial de serem abordados por também serem grandes produtores de energia eólica.



Figura 3.1: Estados selecionados em verde do Nordeste e em amarelo do Sul. Fonte: Elaboração própria.

Com base em [41], séries temporais de geração eólica provém dos dados medidos nas usinas de energia. No entanto, essas medições diretas nem sempre estão disponíveis para todos os locais. Além disso, em muitos casos, a extensão da série temporal é limitada, e os dados estão incompletos ou contêm erros de medição. Estudos de viabilidade de novos parques eólicos também exigem projeções de geração nos locais candidatos baseadas em dados

confiáveis. Na ausência destes, podem ser construídas sinteticamente a partir de dados de reanálise. Bancos de dados de reanálise tornaram-se uma alternativa promissora para estimar a geração devido à disponibilidade de dados para quase toda a superfície da Terra, com um longo histórico de dados. Entre várias opções disponíveis, esses dados também incluem séries temporais de velocidade do vento, a principal entrada para estimar a geração eólica [42, 43].

Atualmente, os principais conjuntos de dados são a segunda versão da *Modern-Era Retrospective analysis for Research and Applications* (MERRA-2) [44], uma evolução do conjunto de dados MERRA, fornecido pela *National Aeronautics and Space Administration* (NASA), e o ERA5, a quinta versão do conjunto de dados do *European Centre for Medium-Range Weather Forecasts* (ECMWF) [43].

O MERRA-2 é um dos conjuntos de dados de reanálise mais amplamente utilizados na literatura para obter séries temporais de velocidade do vento [43, 45]. Nesse sentido, os dados utilizados nesse trabalho serão provenientes dele. Mais especificamente, os dados das regiões em estudo foram coletados por meio de um script automatizado conectado ao site Renewables.ninja [46] e são referentes ao período de Janeiro de 1980 a Dezembro de 2023 [47, 48].

O site Renewables.ninja fornece dados horários, portanto, o script também atuou na transformação dos dados em mensais. As coordenadas para a coleta de dados foram selecionadas com base no *Global Wind Atlas* [49]. Em cada estado, foram selecionados três pontos a 100 metros acima da superfície que apresentavam altas velocidades de vento e não estavam distantes entre si, para garantir que os regimes de vento fossem semelhantes. Em seguida, foi calculada a média das séries temporais dessas três coordenadas, sendo esta utilizada para representar as séries históricas de cada estado. Ressalta-se que a escolha de múltiplos pontos, em vez de um único, visou evitar vieses nos dados e proporcionar uma melhor representatividade ao cobrir uma área maior.

Os dados sobre as anomalias ENSO, onde *El Niño* se refere ao aquecimento das águas do Oceano Pacífico, *La Niña* ao resfriamento e períodos normais são chamados de Neutros, foram divididos em dois grupos: histórico e previsão. Os dados históricos foram obtidos diretamente do *Climate Prediction Center* (CPC) da *National Oceanic and Atmospheric Administration* (NOAA) [50, 51], uma agência americana e referência em estudos ENSO, abrangendo o período de Janeiro de 1931 até Março de 2024, onde a data inicial varia entre os índices do ENSO. A partir da base de dados, foram criadas novas variáveis: a primeira variável consiste na identificação dos períodos de ENSO, classificados como *El Niño*, *La Niña* ou Neutro; as demais representam os índices acumulados ao longo do tempo. Esse conjunto é relevante pois é capaz de investigar se

as séries acumuladas exibem alguma tendência, o que pode indicar variações na pressão e temperatura do mar.

Já os dados de previsão foram obtidos pelo *International Research Institute* (IRI), vinculado ao NOAA. O IRI fornece diversos modelos com um horizonte de até 9 meses de previsão do índice ONI. Foram coletados dois períodos de previsões: o primeiro de Abril de 2023 a Dezembro de 2023, com o intuito de que o ajuste e a previsão sejam melhores do que utilizando os próprios valores observados; e o segundo de Abril de 2024 a Dezembro de 2024 para prever cenários futuros *out-of-sample* [52].

3.2

Modelagem

3.2.1

Modelo Periódico Autorregressivo (PAR)

Conforme Hipel & McLeod [53], o modelo Periódico Autorregressivo (PAR) é uma abordagem de modelagem para séries temporais sazonais. Ao ajustar um modelo PAR a uma série sazonal, ocorre a aplicação de um modelo Autorregressivo (AR) individual para cada período recorrente da sazonalidade. Por exemplo, em uma série com periodicidade mensal, o modelo PAR é configurado para que cada mês tenha seu próprio modelo AR, permitindo a captura mais precisa das variações específicas de cada período ao longo do tempo. O PAR também é referido como PAR(p), em que p representa a ordem do modelo.

Seguindo a notação comumente utilizada ao se referir ao modelo PAR, seja Z uma série com S períodos e N número de anos, então $Z = [z_{(1,1)}, z_{(1,2)}, \dots, z_{(1,S)}, \dots, z_{(N,S)}]$. O modelo PAR da série Z no período m está matematicamente descrito na Equação 3-1.

$$\left(\frac{z_{(t,m)} - \mu_m}{\sigma_m} \right) = \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + a_{t,m}, \quad (3-1)$$

onde μ_m é a média do período m , σ_m é o desvio padrão do período m , $\varphi_i^{(m)}$ é o i -ésimo coeficiente autorregressivo do período m , p_m é a ordem do operador autorregressivo do período m e $a_{t,m}$ é a série de ruídos independentes com média 0 e desvio padrão σ_m^a . No caso particular de Janeiro ($m = 1$), o modelo será aplicado em Dezembro do ano anterior, ou seja, ao momento $(t-1, m-1)$, onde foi assumido que o período de Dezembro é representado por $m = 0 = 12$.

Há, essencialmente, duas abordagens para determinar a ordem autorregressiva de cada mês: a partir da análise da Função de Autocorrelação Periódica (PeACF) e da Função de Autocorrelação Parcial Periódica (PePACF) [54]; ou

por meio de critérios de informação, como o Critério de Informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC), que são métodos de penalização para a seleção de modelos e medidas comparativas da adequação do ajuste, com base no número de parâmetros e na verossimilhança [55].

Ambos os critérios de informação realizam um *trade-off* entre a qualidade do ajuste do modelo testado e sua complexidade, expressa pelo número de parâmetros. Tais critérios não realizam um teste de hipótese, mas oferecem uma avaliação relativa da qualidade dos modelos. Considerando k como o número de parâmetros estimados pelo modelo e \hat{L} como o valor máximo da função de verossimilhança, o AIC e o BIC são calculados conforme as Equações 3-2 e 3-3, respectivamente.

$$AIC = 2k - 2\ln(\hat{L}). \quad (3-2)$$

$$BIC = \ln(n)k - 2\ln(\hat{L}). \quad (3-3)$$

A principal diferença entre esses critérios reside na penalização dos parâmetros, sendo mais rigorosa no BIC em comparação com o AIC. Por essa razão, o BIC é mais recomendado na seleção de um modelo entre uma classe de modelos paramétricos, enquanto o AIC pode ser considerado como uma medida da adequação de ajuste para qualquer modelo [56]. Detalhes adicionais sobre cada critério podem ser encontrados em Akaike [57], Schwarz [55] e Aho et al. [58].

Considerando que o BIC é mais eficaz na escolha de um modelo dentre um grupo, este será adotado para selecionar as ordens de cada período nas séries de velocidade do vento no modelo PAR. Em outras palavras, a ordem escolhida para cada período será aquela que resultar no menor valor de BIC.

Após definir a ordem do modelo é necessário realizar a estimação dos parâmetros $\varphi_i^{(m)}$. Seja $\beta_m = (\varphi_1^{(m)}, \dots, \varphi_{p_m}^{(m)})$ o vetor de parâmetros autorregressivos do período m . Um estimador assintoticamente eficiente, $\hat{\beta}_m$, pode ser obtido ao resolver as Equações 3-4 via Mínimos Quadrados Ordinários (MQO) [59].

$$\gamma_l^{(m)} = \sum_{i=1}^{p_m} \hat{\varphi}_i^{(m)} \gamma_{l-i}^{(m-i)}, l = 1, \dots, p_m. \quad (3-4)$$

3.2.2

Modelo Periódico Autorregressivo com Variáveis Exógenas (PARX)

O modelo Periódico Autorregressivo com Variáveis Exógenas (PARX) é uma extensão do modelo PAR, no qual além da estrutura autorregressiva por períodos sazonais, incorpora uma variável explicativa adicional, representada

por X . Essa variável auxiliar, X , permite que o modelo leve em consideração e capture os efeitos e influências dessa variável sobre a série temporal sazonal, oferecendo uma análise mais abrangente e possivelmente uma melhor capacidade de previsão ao considerar fatores externos que impactam a sazonalidade da série.

Seja Z a série periódica previamente definida e X como a variável exógena na modelagem de Z , com o mesmo número de observações ($N \times S$) e periodicidade (S) de Z . De acordo com Ursu & Pureau [60] e Silveira et al. [61], o modelo Periódico Autorregressivo com uma variável exógena (PARX) para a variável dependente Z e a variável exógena X pode ser matematicamente expresso da seguinte forma:

$$\left(\frac{z_{(t,m)} - \mu_m}{\sigma_m} \right) = \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + \sum_{j=0}^{v_m} \theta_j^{(m)} \left(\frac{x_{(t,m-j)} - \mu_{m-j}^{(x)}}{\sigma_{m-j}^{(x)}} \right) + a_{t,m}, \quad (3-5)$$

onde, μ_m é a média da variável dependente Z do período m , σ_m é o desvio padrão da variável dependente Z do período m , $\varphi_i^{(m)}$ é o i -ésimo coeficiente autorregressivo da variável dependente Z do período m , p_m é a ordem do operador autorregressivo da variável dependente Z do período m . $\mu_m^{(x)}$ é a média da variável independente X do período m , $\sigma_m^{(x)}$ é o desvio padrão de X do período m , $\theta_j^{(m)}$ é o j -ésimo coeficiente autorregressivo da variável exógena X do período m , v_m é a ordem do operador autorregressivo da variável exógena X do período m , e $a_{t,m}$ é a série de ruídos independentes com média 0 e desvio padrão σ_m^a . No caso específico de Janeiro ($m = 1$), uma abordagem semelhante ao PAR é aplicada. O modelo utiliza Dezembro do ano anterior referente ao instante $(t - 1, m - 1)$, onde considera-se que o período de Dezembro é representado por $m = 0 = 12$.

Para determinar as ordens autorregressivas da variável dependente e da variável exógena para cada período (p_m, v_m) , será empregado o critério BIC novamente. No contexto do modelo PARX, para cada período, o BIC obtido será associado ao conjunto (p_m, v_m) . Em outras palavras, o conjunto de parâmetros que resultar no menor valor de BIC será selecionado como o mais adequado para o modelo.

A estimação dos parâmetros do modelo, assim como para o modelo PAR, é realizada via MQO Mínimos Quadrados Ordinários [60]. Considere $Y_{ns+m} = \left(\frac{z_{(t,m)} - \mu_m}{\sigma_m} \right)$ e $X_{ns+m} = \left(\frac{x_{(t,m-j)} - \mu_{m-j}^{(x)}}{\sigma_{m-j}^{(x)}} \right)$, onde $n = 0, \dots, N - 1$ e $m = 1, \dots, s$, com tamanho Ns . Seja $\mathbf{w}_m = [Y_m, Y_{m+s}, \dots, Y_{(N-1)s+m}]$ e $\mathbf{a}_m = [a_m, a_{m+s}, \dots, a_{(N-1)s+m}]$ vetores de dimensão $(N \times 1)$ com T sendo o operador de transposição e $\mathbf{W}_m = [\mathbf{Y}_m, \mathbf{X}_m]$ a matriz com dimensão

$N \times (p_m + 1 + v_m)$, onde \mathbf{Y}_m e \mathbf{X}_m são descritos nas Equações 3-6 e 3-7, respectivamente.

$$\mathbf{Y}_m = \begin{bmatrix} Y_{m-1} & Y_{m-2} & \cdots & Y_{m-p_m} \\ Y_{s+m-1} & Y_{s+m-2} & \cdots & Y_{s+m-p_m} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{(N-1)s+m-1} & Y_{(N-1)s+m-2} & \cdots & Y_{(N-1)s+m-p_m} \end{bmatrix}. \quad (3-6)$$

$$\mathbf{X}_m = \begin{bmatrix} X_m & X_{m-1} & \cdots & X_{m-v_m} \\ X_{s+m} & X_{s+m-1} & \cdots & X_{s+m-v_m} \\ \vdots & \vdots & \ddots & \vdots \\ X_{(N-1)s+m} & X_{(N-1)s+m-1} & \cdots & X_{(N-1)s+m-v_m} \end{bmatrix}. \quad (3-7)$$

Seja

$$\beta_m = (\varphi^{(m)}, \theta^{(m)})^T \quad (3-8)$$

o vetor paramétrico, onde

$$\varphi^{(m)} = (\varphi_1^{(m)}, \dots, \varphi_{p_m}^{(m)})^T; \theta^{(m)} = (\theta_1^{(m)}, \dots, \theta_{v_m}^{(m)})^T. \quad (3-9)$$

Dado que a Equação 3-5 é um modelo linear, pode ser escrita na forma de modelo de regressão:

$$\mathbf{w}_m = \mathbf{W}_m \beta_m + \mathbf{a}_m, m = 1, \dots, s. \quad (3-10)$$

A matriz de covariância do vetor aleatório \mathbf{a}_m é $\sigma_m^2 \mathbf{I}_N$, onde \mathbf{I}_N é a matriz identidade de tamanho N . O estimador de mínimos quadrados de β_m é obtido ao minimizar a Equação 3-11.

$$S(\beta) = \sum_{m=1}^s \mathbf{a}_m^T \mathbf{a}_m = \sum_{n=0}^{N-1} \sum_{m=1}^s \left(Y_{ns+m} - \sum_{i=1}^{p_m} \varphi_i^{(m)} Y_{ns+m-i} - \sum_{j=1}^{v_m} \theta_j^{(m)} X_{ns+m-j} \right)^2. \quad (3-11)$$

Finalmente, ao aplicar o operador de diferença na Equação 3-11 tem-se os estimadores via mínimos quadrados para $\hat{\beta}_m = (\varphi^{(m)}, \theta^{(m)})^T$.

$$\hat{\beta}_m = \{ \mathbf{W}_m^T \mathbf{W}_m \}^{-1} \mathbf{W}_m^T \mathbf{w}_m. \quad (3-12)$$

3.2.3

Covariância (PAR-Cov & PARX-Cov)

Vista a modelagem dos modelos PAR e PARX acima, a correlação atuará em seus resíduos. O conceito de covariância será introduzido entre a velocidade do vento dos estados em cada região brasileira, com o intuito de aprimorar a precisão da modelagem e simulação. Essa metodologia irá avaliar a relação

entre as velocidades do vento em diferentes pontos de um determinado espaço, no caso, os estados brasileiros em estudo. Além disso, a consideração da covariância visa aprimorar a compreensão dos dados de velocidade do vento, identificando padrões, variabilidade e tendências [29, 30, 31].

Essa metodologia pode ser abordada a partir dos seguintes passos:

1. Cálculo da Matriz de Covariância Σ

Para considerar a correlação entre os estados, primeiramente calculou-se a matriz de variâncias e covariâncias entre os estados para cada região, considerando para o cálculo os dados históricos das velocidades do vento.

Ela pode ser representada pela matriz $n \times n$, onde n é o número de estados na região em estudo. A fórmula para calcular a covariância entre dois estados i e j é dada por

$$\text{cov}(X_i, Y_j) = \frac{1}{N-1} \sum_{t=1}^N (X_{i,t} - \bar{X}_i)(Y_{j,t} - \bar{Y}_j), \quad (3-13)$$

onde $X_{i,t}$ e $Y_{j,t}$ são as velocidades do vento nos estados i e j no tempo t , respectivamente, \bar{X}_i e \bar{Y}_j são as médias das velocidades do vento nos estados i e j , respectivamente, e N é o número total de observações.

2. Decomposição Espectral

Após obter a matriz de variâncias e covariâncias, realizou-se a decomposição espectral da mesma. A decomposição espectral de uma matriz simétrica e definida positiva, como a matriz de variâncias e covariâncias, pode ser expressa da seguinte forma:

Seja Σ a matriz de variâncias e covariâncias entre os estados, simétrica $n \times n$ (onde n é o número de estados), ela pode ser decomposta da seguinte maneira:

$$\Sigma = Q\Lambda Q^T, \quad (3-14)$$

onde Q é a matriz cujas colunas são os autovetores de Σ , Λ é a matriz diagonal dos autovalores correspondentes aos autovetores de Σ , e Q^T é a transposta da matriz Q .

A decomposição espectral é crucial nesse contexto porque permite entender melhor a estrutura da matriz de variâncias e covariâncias. Essa decomposição separa a matriz em componentes que revelam informações sobre as direções de maior variabilidade dos dados (representadas pelos autovetores) e o quanto essa variabilidade é explicada por essas direções (dados pelos autovalores).

3. Normal Multivariada

Para obter a distribuição normal multivariada considerando a correlação entre os regimes de vento dos estados, multiplicou-se uma normal multivariada pela matriz de covariâncias decomposta:

$$X = \mu + Q \cdot L \cdot Z, \quad (3-15)$$

onde $X \sim N(\mu, \Sigma)$ é o vetor de variáveis aleatórias representando as velocidades do vento nos estados, μ o vetor de médias das velocidades do vento nos diferentes estados, Q a matriz de autovetores da decomposição espectral da matriz de covariâncias, L a matriz diagonal resultante da raiz quadrada dos autovalores, e Z o vetor de variáveis aleatórias independentes, seguindo uma distribuição normal padrão.

Esse procedimento permite gerar dados simulados que mantêm a estrutura de correlação originalmente presente nos dados históricos das velocidades do vento nos estados.

Dessa maneira, dois novos modelos são criados, o modelo PAR-Cov e o modelo PARX-Cov.

3.3 Pós-Processamento

3.3.1 Métricas de Desempenho

Neste trabalho, serão empregadas três métricas de avaliação de desempenho amplamente utilizadas no contexto da velocidade do vento para estimar a precisão de modelos eólicos no Brasil [62, 63]. Estas métricas incluem duas medidas de erro e uma de ajuste.

Começando pela *Root Mean Square Error* (RMSE), dada por

$$\text{RMSE} = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - f_t)^2}; \quad (3-16)$$

a segunda métrica é chamada de *Mean Absolute Error* (MAE), dada por

$$\text{MAE} = \frac{1}{T} \sum_{t=1}^T |y_t - f_t|; \quad (3-17)$$

a terceira será o Coeficiente de Determinação (R^2), com a seguinte formulação

$$R^2 = 1 - \frac{\sum_{t=1}^T (y_t - f_t)^2}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (3-18)$$

onde y_t representa a velocidade do vento observada no tempo t , f_t é a velocidade do vento prevista pelo modelo no mesmo instante, \bar{y} indica a média observada e T é a extensão do horizonte de previsão.

3.3.2

Geração de Cenários Sintéticos de Velocidade do Vento

Após a seleção dos modelos mais adequados, serão criados cenários sintéticos para a velocidade do vento. O objetivo é, a partir de um dos modelos PAR, PAR-Cov, PARX ou PARX-Cov ajustado à série original, reproduzir o comportamento estocástico e gerar, de maneira sintética, quantas séries temporais novas forem desejadas. Essas séries serão distintas do histórico original, porém igualmente plausíveis do ponto de vista estatístico.

De acordo novamente com o modelo vigente, a estratégia oficial atualmente empregada para gerar séries sintéticas envolve o uso da distribuição Lognormal de três parâmetros ajustada aos resíduos mensais ($a_{t,m}$) do modelo PAR, por dois motivos principais [64]. O primeiro motivo está associado à necessidade de produzir valores sempre positivos, uma vez que se trata de dados eólicos. O segundo motivo decorre da presença de uma forte assimetria nos dados (e resíduos), o que torna inviável o uso da distribuição Normal. Vale ressaltar que a distribuição Lognormal não é a única capaz de atuar na geração de cenários de velocidade do vento. Uma outra opção viável é a utilização da distribuição Weibull de três parâmetros, verificada por Melo et. al [65].

Seguindo Maçaira [24], primeiramente a Equação 3-1 do modelo PAR é manipulada para isolar Z_t :

$$\frac{z_{(t,m)}}{\sigma_m} = \frac{\mu_m}{\sigma_m} + \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + a_{t,m}, \quad (3-19)$$

$$z_{(t,m)} = \frac{\mu_m}{\sigma_m} \sigma_m + \sigma_m \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + \sigma_m a_{t,m}, \quad (3-20)$$

$$z_{(t,m)} = \mu_m + \sigma_m \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + \sigma_m a_{t,m}. \quad (3-21)$$

Assim, para garantir que não sejam gerados valores negativos de $z_{(t,m)}$:

$$z_{(t,m)} > 0, \quad (3-22)$$

$$\mu_m + \sigma_m \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) + \sigma_m a_{t,m} > 0, \quad (3-23)$$

$$\sigma_m a_{t,m} > -\mu_m - \sigma_m \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right), \quad (3-24)$$

$$a_{t,m} > -\frac{\mu_m}{\sigma_m} - \frac{\sigma_m}{\sigma_m} \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right), \quad (3-25)$$

$$a_{t,m} > -\frac{\mu_m}{\sigma_m} - \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right), \quad (3-26)$$

$$a_{t,m} > \Delta. \quad (3-27)$$

Portanto, a variável Δ é função apenas dos momentos (média e variância) do período m e dos coeficientes autorregressivos e é dada por

$$\Delta_{PAR} = -\frac{\mu_m}{\sigma_m} - \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right). \quad (3-28)$$

Definindo μ_m^a e σ_m^a como a média e o desvio padrão, respectivamente, da série de resíduo do período m ($a_{t,m}$), temos que:

$$\xi_{t,m} \sim N(\mu_\xi, \sigma_\xi^2), \quad (3-29)$$

$$a_{t,m} = e^{\xi_{t,m}} + \Delta, \quad (3-30)$$

$$a_{t,m} \sim \text{LNormal}(\mu_\xi, \sigma_\xi^2, \Delta). \quad (3-31)$$

Por se tratar de ruídos aleatórios:

$$W \sim N(0, 1), \quad (3-32)$$

$$\frac{\xi_{t,m} - \mu_\xi}{\sigma_\xi} = W, \quad (3-33)$$

$$\xi_{t,m} = W\sigma_\xi + \mu_\xi, \quad (3-34)$$

$$a_{t,m} = e^{W\sigma_\xi + \mu_\xi} + \Delta. \quad (3-35)$$

Os parâmetros μ_ξ e σ_ξ são estimados de forma a preservar os momentos dos resíduos, conforme Charbeneau [66] e reproduzido por Pereira et al. [67].

$$\theta = 1 + \frac{\sigma_\xi^2}{(\mu_\xi - \Delta)^2}, \quad (3-36)$$

$$\mu_\xi = \log \left(\frac{\sqrt{\sigma_m^a}}{\sqrt{\theta(\theta - 1)}} \right), \quad (3-37)$$

$$\sigma_\xi = \sqrt{\log(\theta)}. \quad (3-38)$$

O parâmetro Δ , como demonstrado na manipulação das equações do PAR, representa o deslocamento necessário para evitar a geração de valores negativos. Ao manipular as equações dos modelos PARX da mesma maneira, é viável determinar seu próprio Δ , conforme exposto na Equação 3-39.

$$\Delta_{PARX} = -\frac{\mu_m}{\sigma_m} - \sum_{i=1}^{p_m} \varphi_i^{(m)} \left(\frac{z_{(t,m-i)} - \mu_{m-i}}{\sigma_{m-i}} \right) - \sum_{j=0}^{v_m} \theta_j^{(m)} \left(\frac{x_{(t,m-j)} - \mu_{m-j}^{(x)}}{\sigma_{m-j}^{(x)}} \right). \quad (3-39)$$

Uma limitação do método de simulação via distribuição Lognormal é a não-linearidade dos resíduos, como afirmado por Oliveira et al. [68], que sugerem o uso da técnica de *Bootstrap* para resolver essa questão. Contudo, é importante ressaltar que o principal objetivo deste trabalho é apresentar metodologias com capacidade de modelagem superior à atualmente utilizada. Por isso, o método de geração de cenários adotado foi o mesmo do modelo vigente, garantindo que qualquer melhoria observada provenha dos modelos propostos e não da técnica de geração de cenários

4

Análise Descritiva dos Dados

Este capítulo realiza uma análise descritiva dos dados de velocidade do vento e ENSO, tal como a relação existente entre ambas. Toda a análise aqui realizada assim como os resultados foram obtidos utilizando o *software* R na versão de dezembro de 2022 [69]. Seguindo os princípios de ciência aberta, é promovido transparência e acessibilidade dos métodos utilizados, ao disponibilizar toda a metodologia no GitHub (<https://github.com/Coutin22/DissertacaoMestradoRafaelCouto.git>).

4.1

Velocidade do Vento

Inicialmente, após os dados de velocidade do vento serem coletados da base de dados MERRA-2, como mencionado no Capítulo 3.1, a Figura 4.2 apresenta as séries temporais para os estados do Rio Grande do Norte (RN), Paraíba (PB), Pernambuco (PE), Alagoas (AL), Sergipe (SE), Rio Grande do Sul (RS) e Santa Catarina (SC) no período de Janeiro de 1980 a Dezembro de 2023. Observando os gráficos, percebe-se que, no geral, os estados apresentam um comportamento sazonal bem marcado, com destaque para os estados localizados no Nordeste.

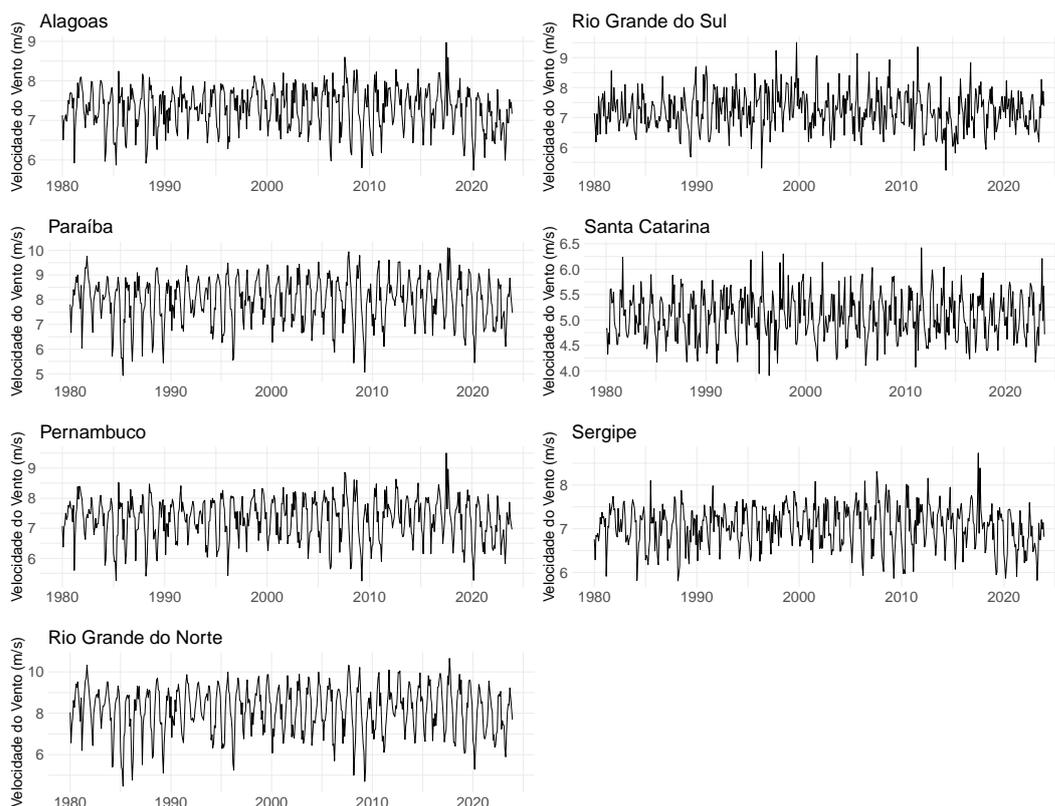


Figura 4.1: Séries Temporais de Velocidade do Vento por Estado. Fonte: Elaborado pelo autor.

É importante também analisar as estatísticas descritivas das séries temporais, mostradas na Tabela 4.1. No que tange às medidas de centralidade, verifica-se a proximidade entre os valores de média e mediana para os estados. Nesse sentido, as maiores médias são observadas, conforme esperado, no Nordeste, pelo Rio Grande do Norte (8,15 m/s) e na Paraíba (7,97 m/s), e a menor média é observada, em Santa Catarina (5,08 m/s). Analogamente, em relação ao desvio padrão e o coeficiente de variação, os estados do Rio Grande do Norte e Paraíba também apresentam as maiores medidas. Quanto à assimetria, todos os valores localizam-se no intervalo $[-1, +1]$, típico de distribuições levemente assimétricas. Já em relação à curtose, nota-se que, os estados apresentam curtose em torno de três, mostrando que tais distribuições possuem uma curva de frequência próxima à distribuição normal.

Tabela 4.1: Estatísticas Descritivas das Séries de Velocidade do Vento por Estado.
Fonte: Elaborado pelo autor.

Estado	Média	Mediana	Desvio Padrão	Coefficiente de Variação	Assimetria	Curtose
Alagoas	7,30	7,36	0,53	0,07	-0,40	2,87
Paraíba	7,97	8,12	0,93	0,12	-0,53	2,94
Pernambuco	7,31	7,43	0,69	0,09	-0,45	2,90
Rio Grande do Norte	8,15	8,34	1,13	0,14	-0,55	2,87
Rio Grande do Sul	7,23	7,21	0,64	0,09	0,24	3,36
Santa Catarina	5,08	5,06	0,44	0,09	0,13	2,71
Sergipe	7,05	7,12	0,48	0,07	-0,21	2,94

Na Figura 4.2 as características de estacionariedade e sazonalidade são verificadas através da função de autocorrelação (FAC). É evidente a presença de picos nos *lags* múltiplos de 12, indicando uma forte correlação das séries com seus próprios valores passados e, conseqüentemente, evidenciando a natureza sazonal das mesmas.

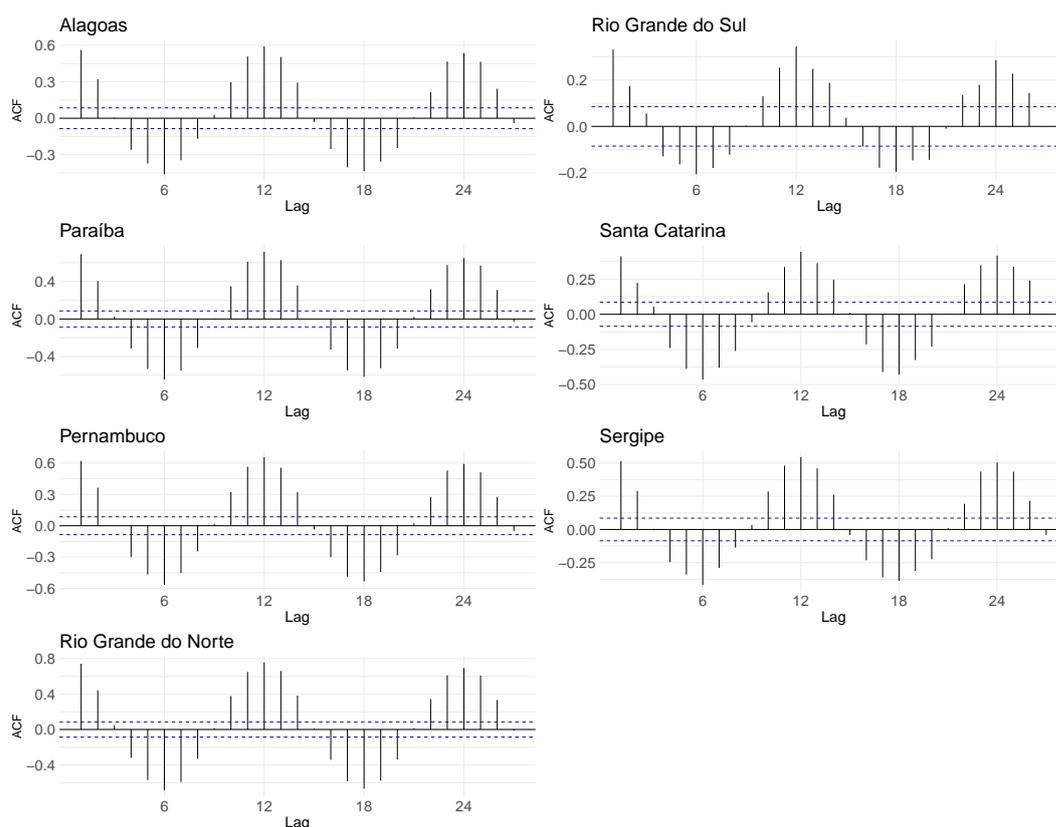


Figura 4.2: Função de Autocorrelação das Séries Temporais de Velocidade do Vento por Estado. Fonte: Elaborado pelo autor.

Para verificar a estacionariedade das séries, foram aplicados os testes de Dickey-Fuller Aumentado (ADF) [70] e de Phillips-Perron (PP) [71]. Os resultados desses testes para cada estado estão apresentados na Tabela 4.2.

Como os p-valores são todos inferiores a um nível de significância de 5%, há evidências estatísticas suficientes para rejeitar a hipótese nula de não-estacionariedade para todos os estados.

Tabela 4.2: P-valor dos Testes de Estacionariedade.

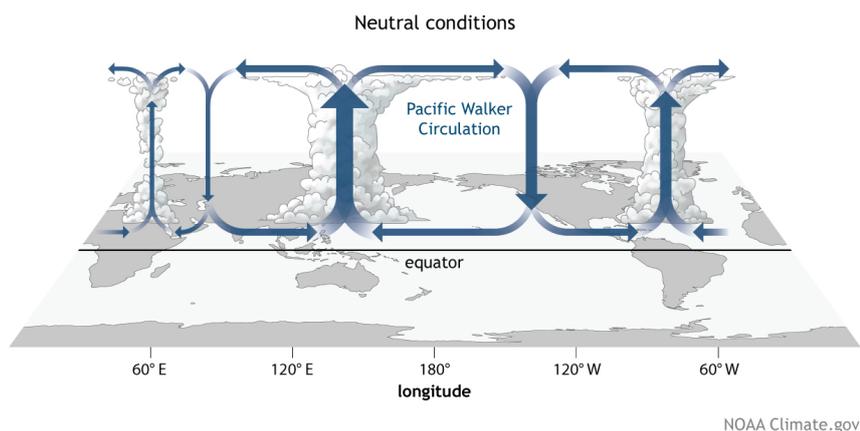
Bacia	ADF	PP	Estacionária?
Alagoas	0.01	0.01	Sim
Paraíba	0.01	0.01	Sim
Pernambuco	0.01	0.01	Sim
Rio Grande do Norte	0.01	0.01	Sim
Rio Grande do Sul	0.01	0.01	Sim
Santa Catarina	0.01	0.01	Sim
Sergipe	0.01	0.01	Sim

4.2 ENSO

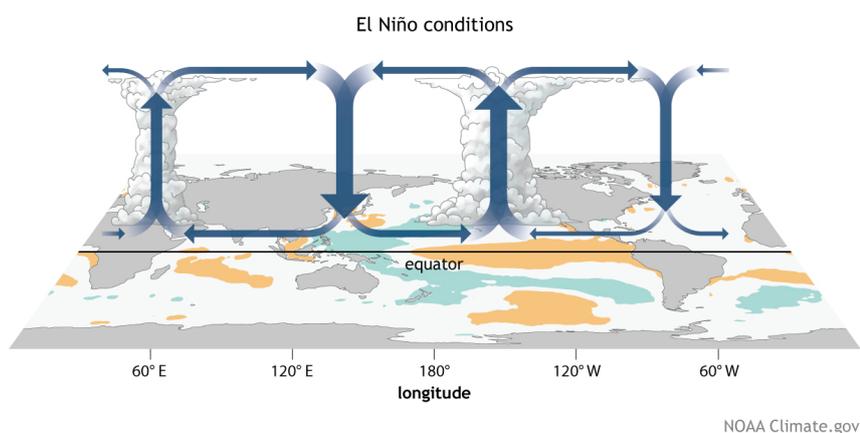
4.2.1 O Fenômeno ENSO

A ocorrência do fenômeno *El Niño* Oscilação Sul (ENSO) desencadeia alterações na circulação atmosférica, impactando significativamente as mudanças climáticas em diversas regiões terrestres. O termo ENSO engloba os fenômenos *El Niño* e *La Niña*, refletindo a influência mútua entre a atmosfera (representada pela Oscilação Sul) e o oceano (associado ao *El Niño/La Niña*). A Oscilação Sul, originalmente definida pelo matemático britânico Sir Gilbert Walker em 1928, se baseia na diferença de pressão atmosférica entre as regiões do Pacífico Sul, ao leste do Tahiti, e do Oceano Índico, a oeste de Darwin, Austrália. Quando a pressão atmosférica é alta em uma região, é baixa na outra e vice-versa.

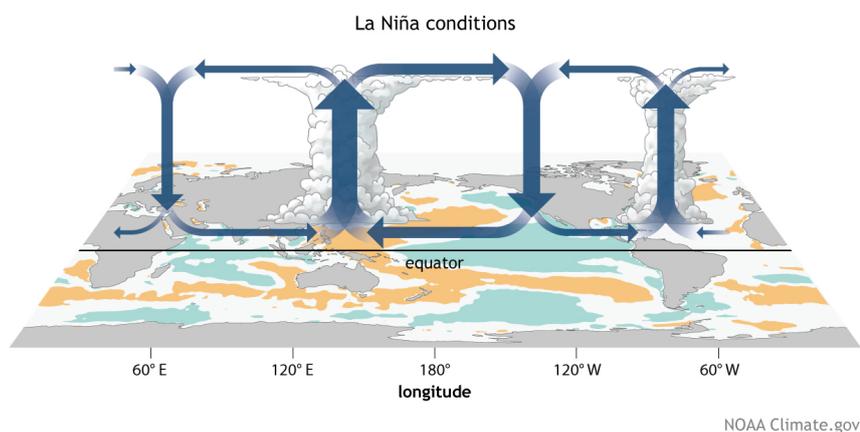
Nos finais dos anos 60, Bjerknes [72] observou que a interação entre o mar e a atmosfera poderia influenciar significativamente a circulação dos ventos, as chuvas e o clima. Prosseguindo os estudos de Walker, ele delineou um padrão de circulação do ar sobre o Pacífico, denominado Circulação de Walker. Durante períodos Neutros, sem *El Niño* ou *La Niña*, há um amplo movimento ascendente de ar na Oceania, com fluxos menores no leste da África e no norte da América do Sul. Entretanto, durante os eventos de *El Niño* e *La Niña*, esses fluxos são deslocados e intensificados. Esta dinâmica pode ser visualizada na Figura 4.3, em que as cores laranja e azul nos oceanos representam, respectivamente, águas mais quentes e mais frias.



(a) Neutro



(b) *El Niño*



(c) *La Niña*

Figura 4.3: Circulação de Walker. Fonte: [73].

De acordo com Oliveira [74], o fenômeno *El Niño* é caracterizado pelo aquecimento anormal das águas no Oceano Pacífico Equatorial, enquanto o *La Niña* representa um resfriamento anormal na mesma região. Durante ambos os eventos, os fluxos ascendentes de ar na Circulação de Walker intensificam-se, devido às variações de temperatura nas águas, direcionando-se para as áreas

com temperaturas elevadas.

Nas últimas décadas, eventos incomuns de *El Niño*, conhecidos como *El Niño Modoki*, têm sido observados. Neste fenômeno, ocorre um aquecimento mais acentuado nas águas do Pacífico Central, particularmente na área designada como Niño 3.4, enquanto a área Niño 1+2, situada no Pacífico Oriental, não é afetada. Como resultado, muitos modelos na literatura usam o índice Niño 3.4 para prever eventos de *El Niño* e *La Niña*. No entanto, de acordo com NOAA [75], diversos outros índices podem ser empregados para caracterizar esses fenômenos.

4.2.2 Índices

O ENSO possui diversos indicadores, localizados em diferentes regiões, cada um com sua importância particular. [76]. O mais antigo é o *Southern Oscillation Index* (SOI) e tem seu cálculo baseado na diferença de pressão atmosférica ao nível do mar entre as regiões do Taiti, no Pacífico Ocidental, e Darwin, na Austrália (Pacífico Oriental). O fato do SOI se basear na pressão do nível do mar em apenas dois pontos mostra que pode ser afetado por flutuações de curto prazo, dia a dia ou semana a semana, não relacionadas ao ENSO. Outra limitação do SOI é que tanto o Taiti quanto Darwin estão localizados ao sul da linha do Equador, enquanto o fenômeno ENSO se concentra mais próximo à mesma linha. Tendo essa situação em vista, o SOI Equatorial supera tal limitação, uma vez que calcula a diferença da média de pressão atmosférica ao nível do mar entre duas regiões centradas na linha do Equador: a Indonésia e o Pacífico Oriental. Ambos podem ser vistos na Figura 4.4.

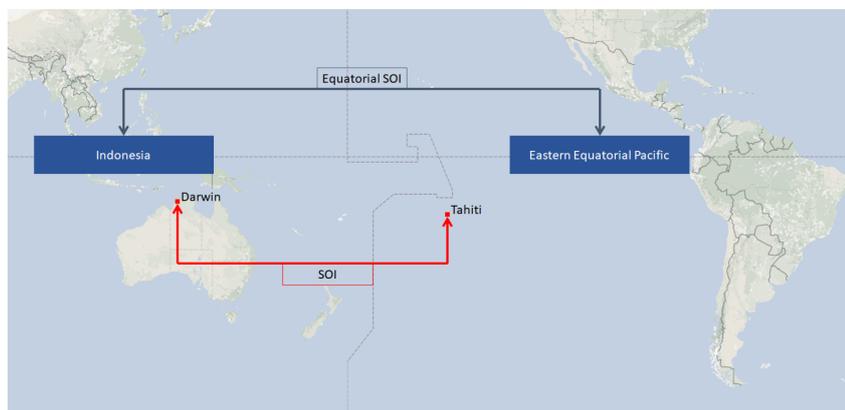


Figura 4.4: Localização do SOI e SOI Equatorial. Fonte: [76].

Em 1969, Bjerknes descobriu que a Temperatura da Superfície do Mar (*Sea Surface Temperature*, SST) no Oceano Pacífico equatorial era peça chave para determinar a ocorrência do fenômeno ENSO, pois é o principal indício

da ocorrência do fenômeno [72]. Inicialmente, certas regiões foram definidas para as medições: Niño 1, Niño 2 (combinado em Niño 1+2), Niño 3 e Niño 4. Mais tarde, uma área chamada Niño 3.4 foi identificada como sendo a mais representativa do ENSO [77]. Localizada entre (e sobreposto com) Niño 3 e Niño 4, esta é a região cuja anomalia de temperatura é refletida pelo *Oceanic Niño Index* (ONI), com a diferença de que o ONI busca remover a tendência de aquecimento existente na região. Para constatar a ocorrência de um fenômeno ENSO são utilizadas as séries de anomalia dos índices, isto é, a diferença de valores entre o período anterior e o período atual, com a diferença que para o ONI, as suas séries de anomalias são calculadas através da média móvel de três meses em cima da diferença de valores entres os períodos. Essas regiões podem ser visualizadas na Figura 4.5.



Figura 4.5: Localização do SST e ONI. Fonte: [76].

Em relação ao SOI, períodos consecutivos de índices positivos com cinco valores mensais acima de $0,5^\circ$ evidenciam a ocorrência do fenômeno *La Niña*. Já períodos negativos com cinco valores mensais consecutivos abaixo de $-0,5^\circ$ evidenciam a presença do *El Niño*. No caso da SST, os períodos consecutivos de índices positivos com cinco valores mensais acima de $0,5^\circ$ evidenciam a ocorrência do fenômeno *El Niño* e os períodos negativos com cinco valores mensais consecutivos abaixo de $-0,5^\circ$ evidenciam a presença da *La Niña* [50].

4.2.2.1 Histórico

Para todos os índices do ENSO, foram feitos os gráficos da Figura 4.6, apresentando os históricos mensais das variáveis de 1931 a Março de 2024, com a data de início variando conforme os índices do ENSO. Em relação aos índices SOI a sequência de pontos acima da linha azul indicam a ocorrência de eventos *La Niña* e a sequência de pontos abaixo da linha vermelha, de eventos *El Niño*. Já para os índices SST e ONI a sequência de pontos acima

da linha vermelho indicam a ocorrência de eventos *El Niño* e a sequência de pontos abaixo da linha azul, de eventos *La Niña*. Todos os índices seguem as diretrizes mencionadas.

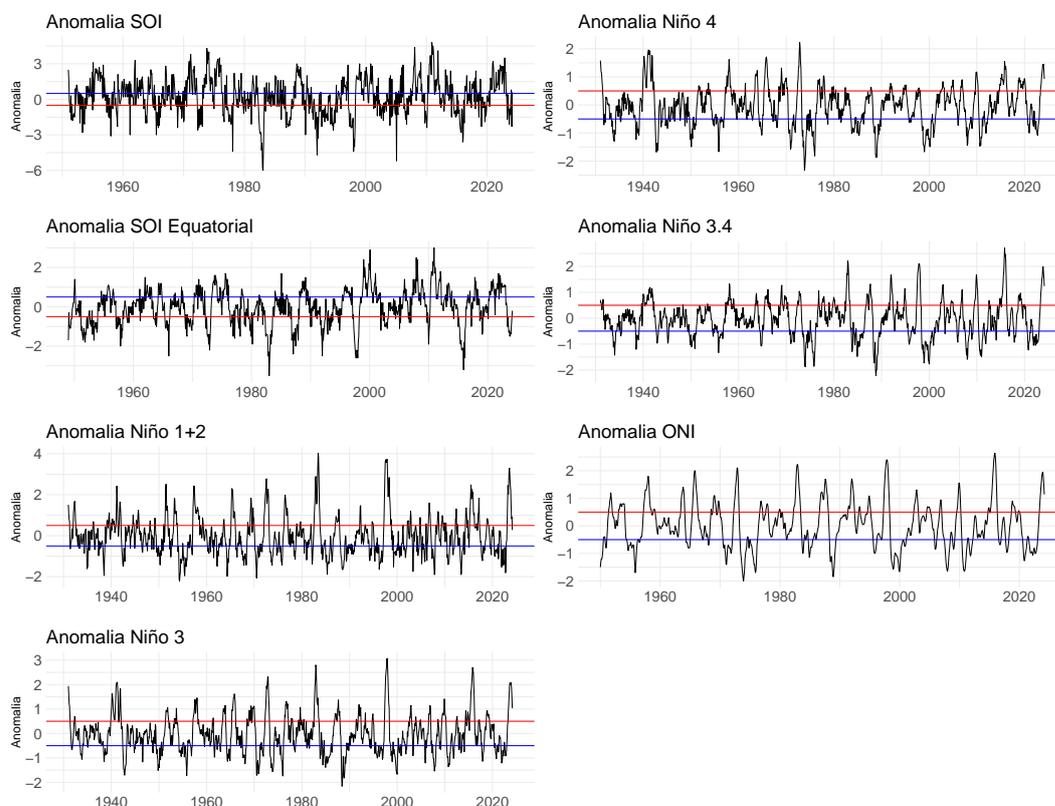


Figura 4.6: Séries Temporais das Anomalias dos Índices Históricos do ENSO. Fonte: Elaborado pelo autor.

Já as séries acumuladas podem ser observadas na Figura 4.7, mostrando que, segundo os índices SOI e SOI Equatorial, há tendência de crescimento da pressão atmosférica na superfície do mar tanto entre as regiões do Taiti e Darwin, como entre a Indonésia e o Pacífico Oriental recentemente. Também na Figura 4.7 são apresentados os índices acumulados para SST e ONI. Note que após 1980, todos esses índices, com exceção do ONI, apresentam tendência de queda.

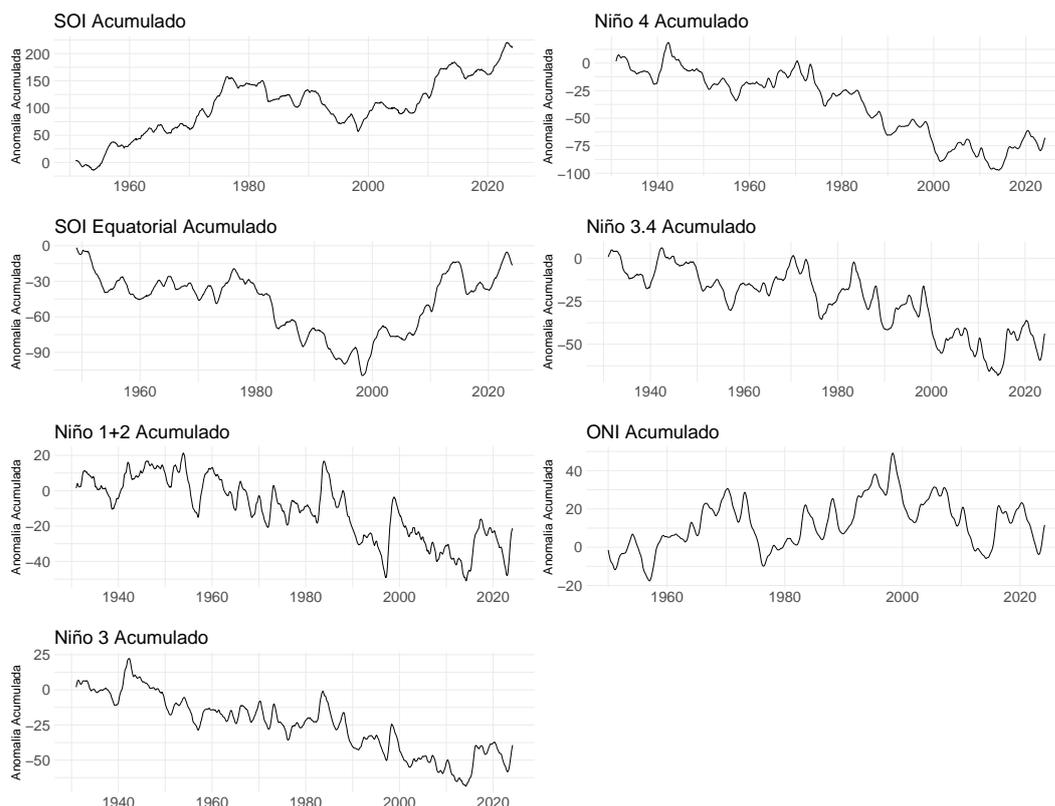


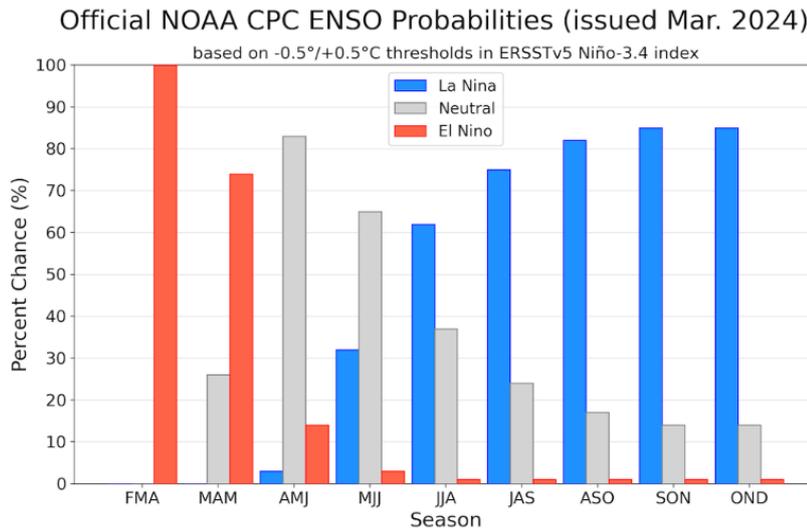
Figura 4.7: Séries Temporais das Anomalias Acumuladas dos Índices Históricos do ENSO. Fonte: Elaborado pelo autor.

4.2.2.2 Previsão

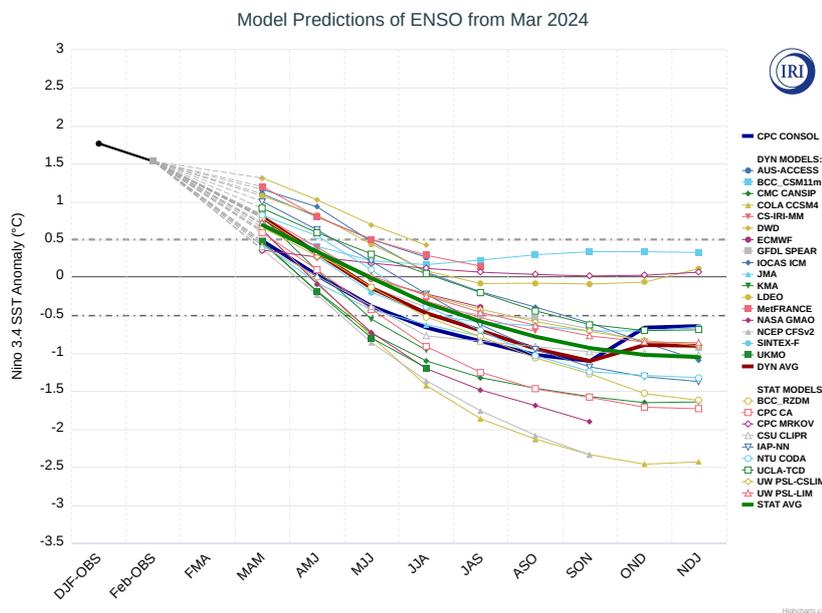
A previsão do índice ONI de Abril de 2024 a Dezembro de 2024 será utilizada para auxiliar a prever cenários futuros de velocidade do vento, como mencionado no Capítulo 3.1. Essa previsão será analisada a seguir.

As previsões oficiais de probabilidade de fases do ENSO pelo CPC são baseadas em um consenso dos seus meteorologistas e do IRI. Elas são fundamentadas em informações observacionais e preditivas do início do mês e do mês anterior, ou seja, além da análise da saída de diversos modelos, também utiliza-se o julgamento humano. Os modelos são aplicados pelo IRI para gerar as previsões das anomalias do índice ONI do ENSO. Eles são divididos em dois grupos: dinâmicos e estatísticos, incluindo suas médias, além do modelo consolidado do CPC do NOAA, que é baseado na média de modelos específicos [52].

Na Figura 4.8, observa-se que as previsões sugerem uma transição do *El Niño* para a *La Niña* em 2024, destacado pelas Probabilidades de Fases. Junto à isso, as Anomalias refletem uma queda brusca das anomalias do índice ONI.



(a) Probabilidades de Fases



(b) Anomalias

Figura 4.8: Previsões das Probabilidades de fases e de Anomalias do ENSO - 2024. Fonte: [52].

A média das anomalias de todos os modelos do índice ONI também é disponibilizada e será utilizada nesse trabalho. Entretanto, também torna-se necessário a obtenção da previsão das anomalias dos outros índices, que não são disponibilizados pelo IRI. Para isso foi aplicada uma Regressão Linear [78].

Primeiramente, foi feito um ajuste entre os dados observados de cada um dos índices e o ONI. Os resultados da regressão podem ser vistos na Tabela 4.3. Junto a isso, foram feitos gráficos de dispersão para os seis índices (Figura 4.9). Os resultados mostram que os índices que obtiveram os melhores ajustes foram o Niño 3.4 e Niño 3 com R^2 de 0,882 e 0,831, respectivamente.

Tabela 4.3: Ajuste dos Índices do ENSO ao ONI - 2024. Fonte: Elaborado pelo autor.

Índice	Coefficientes	Valor Estimado	Desvio Padrão	P-valor	R ²
SOI	(Intercepto)	0,275	0,036	≈ 0	0,528
	ONI	-1,349	0,043	≈ 0	
SOI Equatorial	(Intercepto)	0,001	0,017	0,938	0,701
	ONI	-0,909	0,02	≈ 0	
Niño 1+2	(Intercepto)	-0,046	0,026	0,072	0,444
	ONI	0,811	0,03	≈ 0	
Niño 3	(Intercepto)	-0,046	0,011	≈ 0	0,831
	ONI	0,898	0,014	≈ 0	
Niño 4	(Intercepto)	-0,072	0,01	≈ 0	0,792
	ONI	0,728	0,013	≈ 0	
Niño 3.4	(Intercepto)	-0,052	0,009	≈ 0	0,882
	ONI	0,837	0,01	≈ 0	

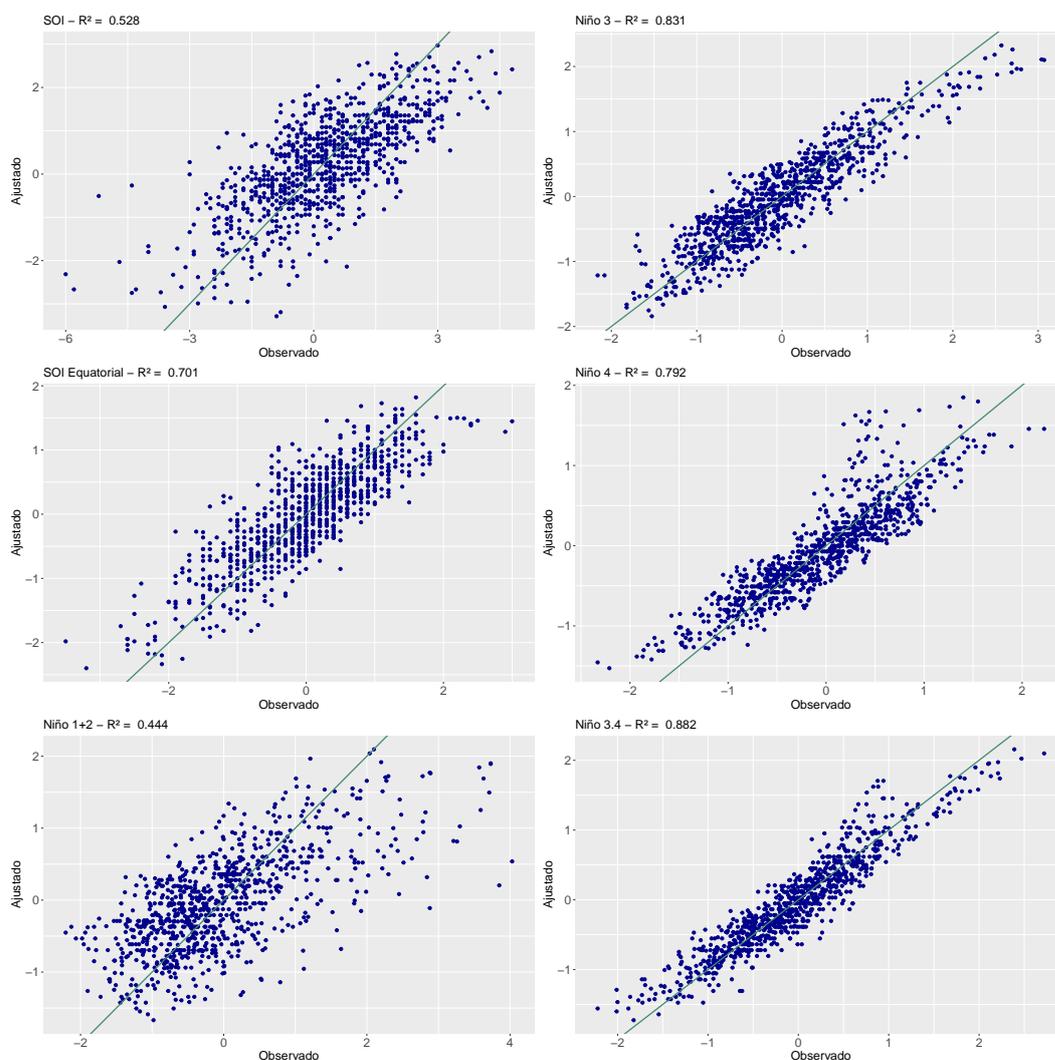


Figura 4.9: Gráficos de Dispersão dos Valores Observados x Ajustados dos Índices - 2024. Fonte: Elaborado pelo autor.

A partir disso, pode-se construir a previsão dos índices a partir do ONI. Na Figura 4.10 é possível observar essas previsões em laranja, juntas ao seus históricos desde 2010, em azul.

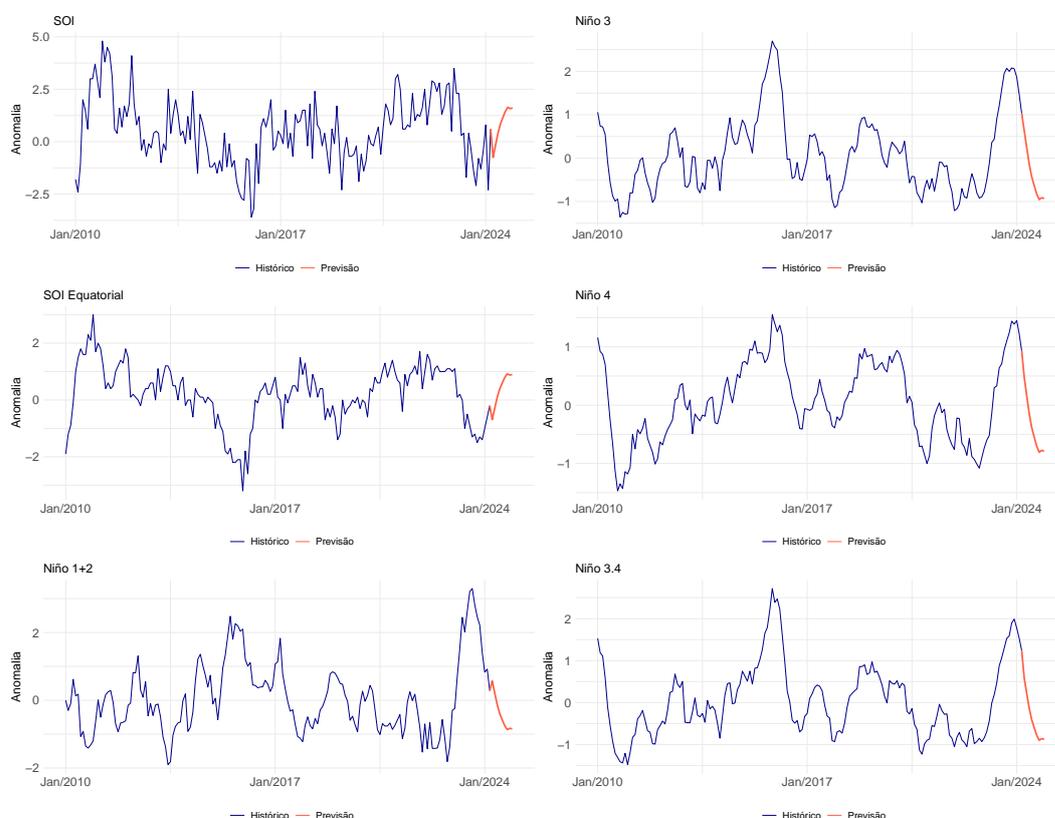


Figura 4.10: Previsão dos Índices ENSO - 2024. Fonte: Elaborado pelo autor.

4.3

Relação entre Velocidade do Vento e ENSO

A fim de avaliar estatisticamente as diferenças das distribuições das fases do ENSO, quando é caracterizado *El Niño*, *La Niña* e também em períodos considerados neutros, isto é, quando não há nenhum evento, foi realizado o Teste de Kruskal-Wallis [79]. Ele é utilizado para comparar mais de dois grupos independentes, de tamanhos iguais ou não, com variável resposta quantitativa. O teste dispensa a pressuposição de normalidade e homoscedasticidade. As hipóteses do teste são as seguintes:

H_0 : As k amostras são oriundas de uma mesma população.

H_1 : Pelo menos uma das amostras vem de uma população distinta das demais.

Para avaliar o teste optou-se por um nível de significância de 10%, onde *Sim* representa que as fases possuem a mesma distribuição e, portanto, a

hipótese nula não é rejeitada; **Não** representa que as fases não possuem a mesma distribuição e, dessa forma, a hipótese nula é rejeitada.

Tabela 4.4: P-Valor e Respostas do Teste de Kruskal-Wallis. Fonte: Elaborado pelo autor.

Estado	SOI	SOI Equatorial	Niño 1+2	Niño 3	Niño 4	Niño 3.4	ONI
Alagoas	0.426	0.93	0.123	0.801	0.662	0.801	0.645
	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Paraíba	0.262	0.918	0.013	0.312	0.097	0.197	0.788
	Sim	Sim	Não	Sim	Não	Sim	Sim
Pernambuco	0.587	0.73	0.02	0.168	0.117	0.204	0.682
	Sim	Sim	Não	Sim	Sim	Sim	Sim
Rio Grande do Norte	0.065	0.852	0.023	0.787	0.193	0.26	0.609
	Não	Sim	Não	Sim	Sim	Sim	Sim
Rio Grande do Sul	0.492	0.102	0.308	0.075	0.749	0.335	0.093
	Sim	Sim	Sim	Não	Sim	Sim	Não
Santa Catarina	0.167	0.174	0.001	0.545	0.395	0.378	0.259
	Sim	Sim	Não	Sim	Sim	Sim	Sim
Sergipe	0.466	0.89	0.099	0.494	0.354	0.925	0.755
	Sim	Sim	Não	Sim	Sim	Sim	Sim

É possível notar que todos os estados, com exceção de Alagoas, possuem ao menos um índice comprovando que as distribuições entre as fases são distintas. Dessa forma, prova-se estatisticamente que o fenômeno climático ENSO pode influenciar o comportamento da velocidade do vento nos locais em estudo como um todo.

Para uma melhor visualização dos resultados acima, foi realizada uma análise por meio de box-plots da velocidade do vento dos estados quando são caracterizadas as três fases do ENSO, utilizando o indicador que obteve o menor p-valor. É possível notar na Figura 4.11 que há de fato diferenças nas velocidades do vento por evento ENSO, com destaque para *La Niña*.

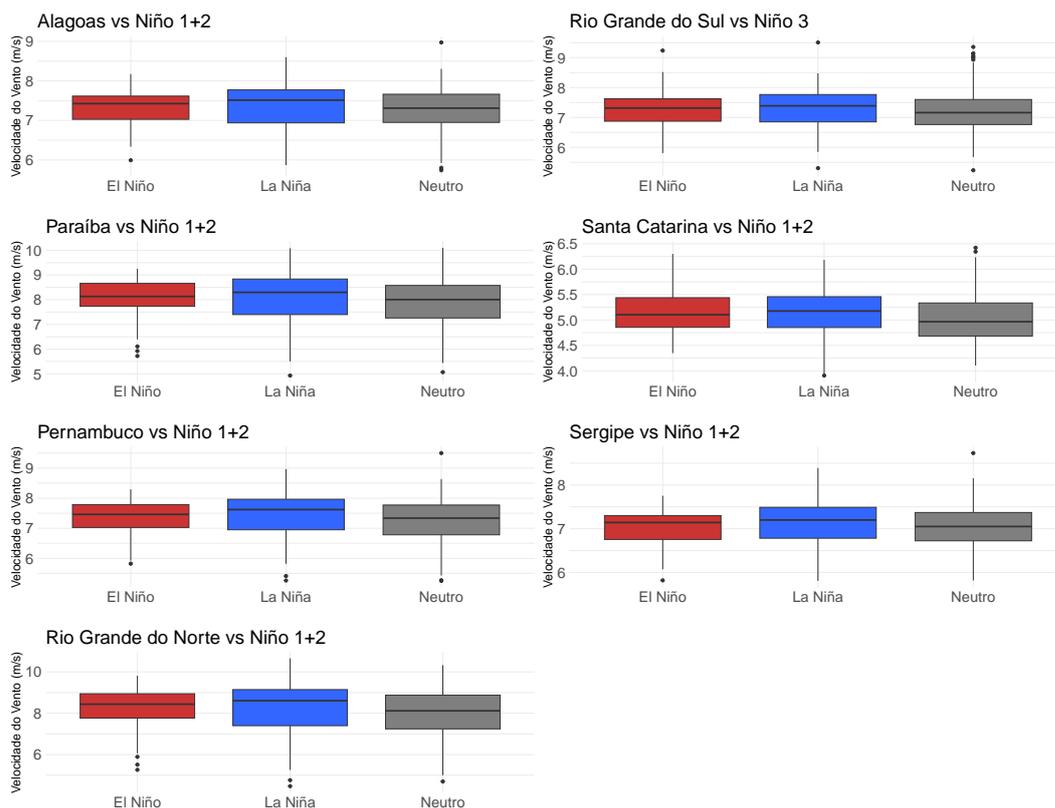


Figura 4.11: Comportamento da Velocidade do Vento por Evento ENSO. Fonte: Elaboração própria.

5

Resultados

Inicialmente, os modelos propostos serão avaliados quanto à sua capacidade de previsão, gerando cenários de velocidade do vento somente com o modelo selecionado. Para avaliar o desempenho de cada modelo, os conjuntos de dados foram divididos em sete janelas de ajuste e previsão, detalhadas na Tabela 5.1.

Tabela 5.1: Janelas de Ajuste e Previsão. Fonte: Elaborado pelo autor.

Janela	<i>In-sample</i>	<i>Out-of-sample</i>
1	Jan/1980-Dez/2013	Jan/2014-Dez/2018
2	Jan/1980-Dez/2014	Jan/2015-Dez/2019
3	Jan/1980-Dez/2015	Jan/2016-Dez/2020
4	Jan/1980-Dez/2016	Jan/2017-Dez/2021
5	Jan/1980-Dez/2017	Jan/2018-Dez/2022
6	Jan/1980-Dez/2022	Jan/2023-Dez/2023
7	Jan/1980-Dez/2023	Jan/2024-Dez/2024

Na janela 1, será determinada a seleção dos parâmetros $p(v)$ e $m(v)$ para os modelos PARX e PARX-Cov. Isto é, para cada estado e para cada combinação de parâmetros, os passos a seguir devem ser executados, considerando exclusivamente a primeira janela.

- i) Ajustar a série de velocidade do vento para o período *in-sample*;
- ii) Simular cenários do período *out-of-sample* (utilizando os próprios valores observados das variáveis climáticas no período *in-sample*);
- iii) Comparar os valores previstos, calculado pela média dos cenários, com valor observado;
- iv) Guardar os erros obtidos.

Os parâmetros selecionados para cada estado e modelo serão aqueles que resultarem no menor erro. Esses parâmetros serão aplicados nas janelas 2 a 5 para calcular as métricas de desempenho, mantendo os procedimentos da janela 1, mas focando exclusivamente na melhor combinação identificada inicialmente. A média dos valores de erro e ajuste apresentados nesta seção é calculada nas quatro janelas (2 a 5), com o objetivo de avaliar de forma mais robusta a capacidade preditiva dos modelos, utilizando as métricas RMSE,

MAE e R^2 . A partir desses resultados, serão escolhidos os melhores modelos para cada estado.

Com a seleção dos melhores modelos concluída, o próximo passo será aplicar esses modelos na janela 6, usando o ENSO previsto para 2023, obtido de forma análoga ao método utilizado para o período de 2024 (conforme descrito no Apêndice A). Finalmente na janela 7, será realizada uma previsão de cenários futuros para 2024, empregando dados do ENSO *out-of-sample*, com base nos modelos previamente identificados como os melhores.

Uma tabela com abreviações dos modelos será fornecida (Tabela 5.2) para facilitar a compreensão das siglas utilizadas posteriormente.

Tabela 5.2: Resumo das variáveis a serem utilizadas.

Abreviação	Variável
SOI	Southern Oscillation Index
EQ SOI	Equatorial SOI
NINO1+2	Sea Surface Temperature - Niño 1+2
NINO3	Sea Surface Temperature - Niño 3
NINO3.4	Sea Surface Temperature - Niño 3.4
NINO4	Sea Surface Temperature - Niño 4
ONI	Oceanic Niño Index
ACUM	Acumulado

Na Figura 5.1, é apresentada a performance das janelas 2 a 5, medida pela métrica RMSE, para todos os modelos testados em cada estado. A métrica do modelo PAR está representada em vermelho, a do modelo PAR-Cov em laranja. Os modelos PARX e PARX-Cov, que apresentaram as menores métricas utilizando o fenômeno ENSO, estão destacados em verde e roxo, respectivamente. Cada um desses dois tipos de modelo possui 14 variantes (7 índices e 7 índices acumulados), totalizando 28 modelos. Os demais modelos PARX e PARX-Cov estão representados em cinza. No total, o gráfico exibe 30 modelos. É possível concluir que para todos os estados foi possível encontrar um modelo PARX ou PARX-Cov que apresente erro menor que a metodologia PAR (*benchmark*) ao utilizar um índice que represente o *El Niño* e *La Niña*.

De forma análoga, no Apêndice B foi exibido graficamente o resultados de todos os modelos segundo as métricas MAE e R^2 , também encontrando para todos os estados um modelo com variável exógena com desempenho melhor que o *benchmark*.

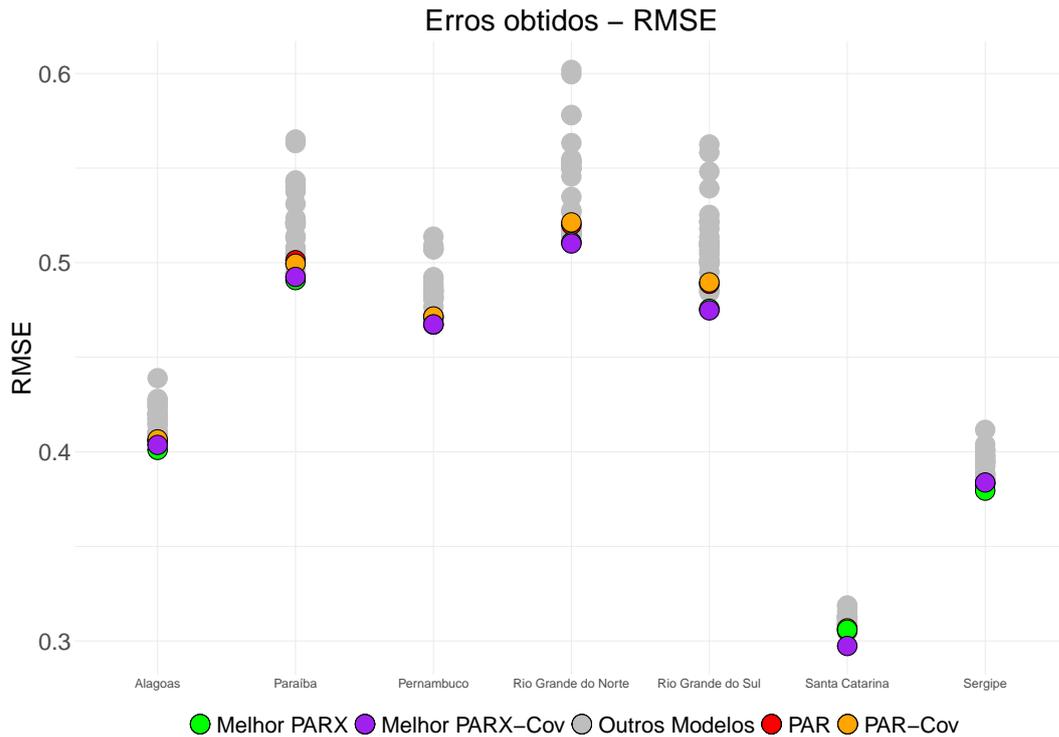


Figura 5.1: RMSE obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.

A Tabela 5.3 destaca os modelos com melhor desempenho conforme as métricas RMSE, MAE e R^2 , incluindo a melhoria em relação ao modelo PAR. É importante notar sobre a métrica RMSE, que os estados que apresentaram as maiores melhorias foram Rio Grande do Sul (2,87%) e Santa Catarina (2,65%), empregando modelos PARX-Cov. Por outro lado, o estado de Pernambuco registrou a menor melhoria (0,87%), ainda apresentando uma vantagem sobre o PAR. Destaca-se na métrica MAE, a maior melhoria, mais uma vez vindo da Região Sul, com 4,47% por meio de um modelo PARX-Cov para Santa Catarina. Nota-se também a Paraíba com uma melhoria de 2,19%, com um modelo PARX. Por fim, revela-se na métrica R^2 um pequeno ganho para o estado do Rio Grande do Norte (0,71%), enquanto que o estado do Rio Grande do Sul apresentou um grande ganho de 19,29%, por meio de um modelo PARX-Cov.

Tabela 5.3: Melhores modelos nas janelas 2 a 5 para as métricas RMSE, MAE e R^2 . Fonte: Elaborado pelo autor.

Estado	Métrica	PAR	Melhor Modelo		Melhoria (%)
Alagoas	RMSE	0,4057	PARX + ONI ACUM	0,401	1,15
	MAE	0,312	PARX + ONI ACUM	0,3077	1,36
	R^2	0,476	PARX + ONI ACUM	0,4878	2,48
Paraíba	RMSE	0,5013	PARX + NINO4 ACUM	0,4908	2,09
	MAE	0,3867	PARX + ONI ACUM	0,3782	2,19
	R^2	0,7418	PARX + NINO4 ACUM	0,7522	1,4
Pernambuco	RMSE	0,4714	PARX + ONI ACUM	0,4673	0,87
	MAE	0,3688	PARX-Cov + ONI ACUM	0,3632	1,49
	R^2	0,6	PARX-Cov + NINO3.4 ACUM	0,6068	1,12
Rio Grande do Norte	RMSE	0,52	PARX-Cov + SOI	0,5102	1,88
	MAE	0,4064	PARX + ONI ACUM	0,3996	1,69
	R^2	0,8045	PARX-Cov + SOI	0,8102	0,71
Rio Grande do Sul	RMSE	0,4888	PARX-Cov + ONI ACUM	0,4748	2,87
	MAE	0,3867	PARX + ONI ACUM	0,3798	1,8
	R^2	0,2263	PARX-Cov + ONI ACUM	0,27	19,29
Santa Catarina	RMSE	0,3055	PARX-Cov + ONI ACUM	0,2974	2,65
	MAE	0,2479	PARX-Cov + ONI ACUM	0,2368	4,47
	R^2	0,429	PARX-Cov + ONI ACUM	0,459	6,99
Sergipe	RMSE	0,3829	PARX + ONI ACUM	0,3795	0,89
	MAE	0,2931	PARX + ONI ACUM	0,2887	1,53
	R^2	0,422	PARX + ONI ACUM	0,4321	2,4

A Tabela 5.4 apresenta um resumo dos modelos destacados como os melhores, considerando as três métricas de desempenho para cada um dos sete estados, formando 21 casos possíveis. Observa-se que todos os modelos selecionados incorporam a variável exógena ENSO na modelagem, indicando sua contribuição significativa, com o índice ONI sendo o mais prevalente, com 16 ocorrências. Além disso, destaca-se que 9 dos modelos são PARX-Cov, evidenciando a importância da inclusão da covariância.

Tabela 5.4: Resumo dos modelos mais escolhidos como melhores.

Modelo	Frequência (de 21)
PARX + ONI ACUM	10
PARX-Cov + ONI ACUM	6
PARX + NINO4 ACUM	2
PARX-Cov + SOI	2
PARX-Cov + NINO3.4 ACUM	1

Levando em consideração as três métricas de desempenho avaliadas na Tabela 5.3, o melhor modelo para cada estado foi selecionado com base na maioria das métricas que indicaram esse modelo como o melhor. A exceção foi o estado de Pernambuco, onde cada métrica apontou um modelo diferente como

o melhor. Nesse caso, foi escolhida a métrica que indicou a maior melhoria. Os melhores modelos escolhidos estão apresentados na Tabela 5.5.

Tabela 5.5: Melhor modelo com um índice ENSO selecionado para cada Estado.

Estado	Melhor Modelo
Alagoas	PARX + ONI ACUM
Paraíba	PARX + NINO4 ACUM
Pernambuco	PARX-Cov + ONI ACUM
Rio Grande do Norte	PARX-Cov + SOI
Rio Grande do Sul	PARX-Cov + ONI ACUM
Santa Catarina	PARX-Cov + ONI ACUM
Sergipe	PARX + ONI ACUM

Finalmente, na Figura 5.2 são apresentadas as velocidades do vento observadas durante o período de validação da janela 6 (Jan/2023-Dez/2023) em preto, e previsões obtidas ao utilizar o PAR em vermelho e o melhor modelo PARX ou PARX-Cov (azul escuro) para cada estado.

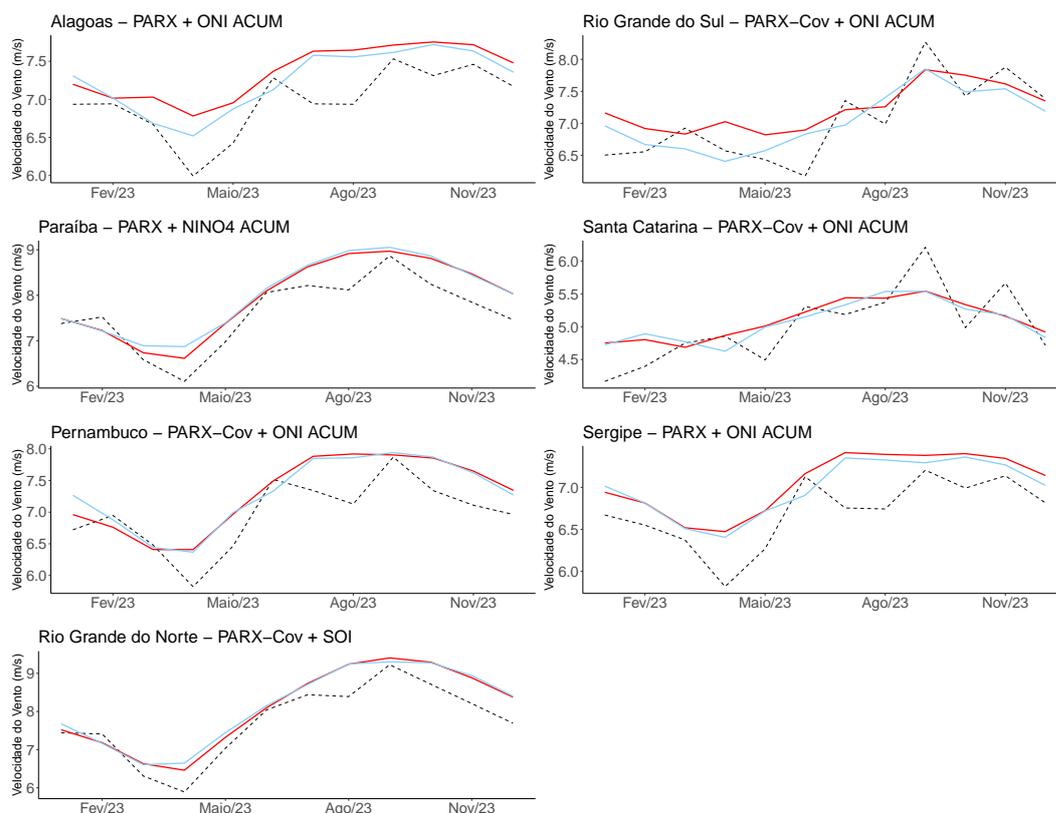


Figura 5.2: Velocidade do vento observada (preto), e previsões obtidas via modelo PAR (vermelho) e o melhor modelo PARX ou PARX-Cov (azul escuro), sobre a janela 6. Fonte: Elaborado pelo autor.

Como visto na Seção 4.2.2.2, é esperado que para 2024 ocorra uma transição do *El Niño* para a *La Niña*, com uma queda brusca das anomalias do índice ONI. Nesse sentido, na Figura 5.3 são apresentados para cada estado os cenários (azul claro) e as previsões sobre a janela 7 (Jan/2024-Dez/2024) obtidas ao utilizar o melhor modelo PARX ou PARX-Cov (azul escuro), que utiliza a variável climática ENSO *out-of-sample*, e o modelo PAR (*benchmark*), em vermelho.

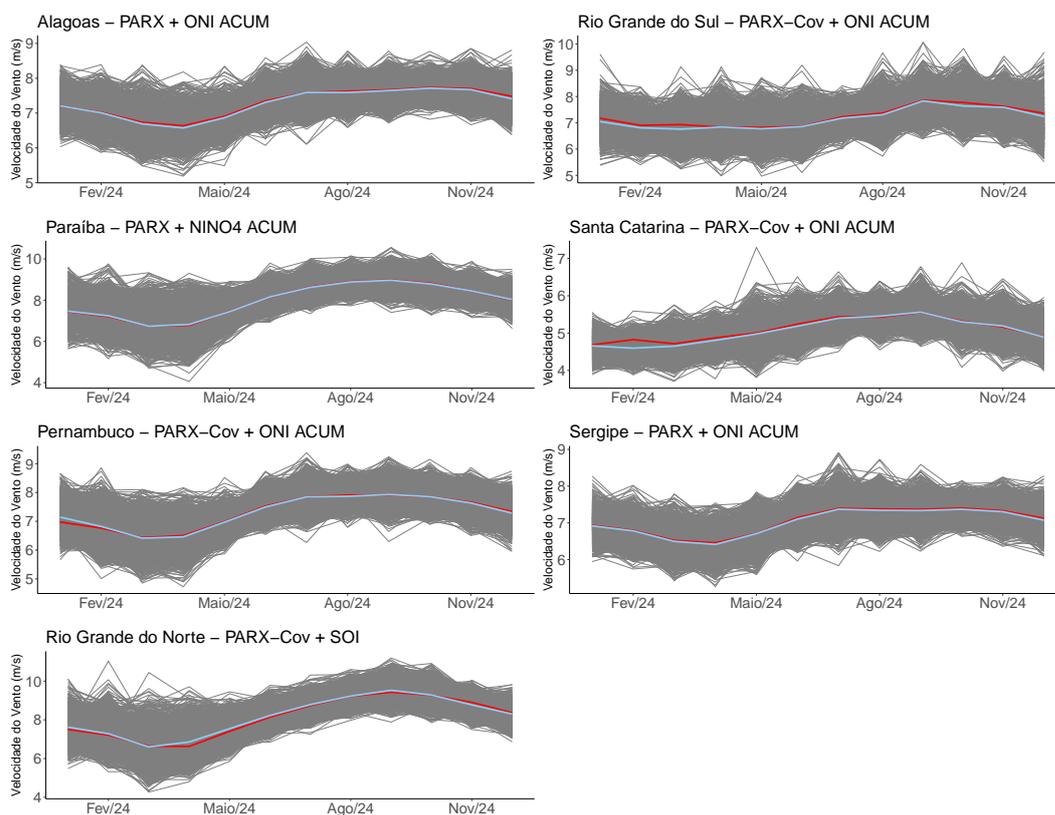


Figura 5.3: Cenários (azul claro), e previsões obtidas pelo melhor modelo PARX ou PARX-Cov (azul escuro) e o modelo PAR (vermelho), sobre a janela 7. Fonte: Elaborado pelo autor.

6

Conclusão

Devido ao grande crescimento da energia eólica no Brasil em resposta às mudanças climáticas atuais [9], este trabalho propõe uma abordagem metodológica capaz de incorporar variáveis climáticas para aperfeiçoar a modelagem e simulação no setor elétrico, contribuindo para reduzir as incertezas. A proposta envolve a adição de uma variável explicativa ao modelo Periódico Autorregressivo (PAR) para séries de velocidade do vento, atualmente utilizado no setor elétrico brasileiro [3], através do uso do modelo Periódico Autorregressivo com Variáveis Exógenas (PARX), incluindo a variável exógena ENSO. Este modelo foi aplicado a dados de reanálise de velocidade do vento de regiões litorâneas com alta geração eólica, abrangendo cinco estados do Nordeste (Rio Grande do Norte, Paraíba, Pernambuco, Alagoas e Sergipe) e dois estados do Sul (Rio Grande do Sul e Santa Catarina).

Para aprimorar a precisão da modelagem e simulação, propõe-se a introdução da covariância entre esses estados em cada região brasileira. A análise da correlação espacial assume importância crucial para compreender as interconexões, agregando uma dimensão adicional à abordagem metodológica proposta, criando assim, os modelos PAR-Cov e PARX-Cov. Além disso, previsões de ONI do fenômeno ENSO para nove meses foram coletadas, junto a uma abordagem desenvolvida para considerar a correlação entre os indicadores do ENSO e viabilizar a previsão *out-of-sample* das demais variáveis climáticas, com o intuito de que o ajuste e a previsão fossem superiores ao se utilizar os próprios valores observados. Por fim, foi utilizado a previsão *out-of-sample* das variáveis climáticas para simulação de cenários futuros de velocidade de vento. Esses cenários foram gerados garantindo a não ocorrência de valores negativos.

A análise descritiva das séries de velocidade do vento permitiu identificar que os estados apresentam um comportamento sazonal bem marcado, com destaque para os localizados no Nordeste. Destaca-se as maiores médias são observadas pelo Rio Grande do Norte e na Paraíba, e a menor em Santa Catarina. Além disso, características de estacionariedade e sazonalidade foram verificadas por meio da FAC, e dos testes ADF e Phillips-Perron.

Em relação a análise descritiva das variáveis climáticas referentes ao ENSO, foram observados o histórico e a previsão. Dentro dos seus índices, tem-se o Southern Oscillation Index (SOI) e o SOI Equatorial, que tratam da pressão atmosférica ao nível do mar, e os índices Sea Surface Temperature (SST), incluindo o Oceanic Niño Index (ONI), que analisam a temperatura da superfície do mar. Todos esses índices foram utilizados para quantificar os fenômenos *El Niño* e *La Niña*, que se referem ao aquecimento e o resfriamento

da água, respectivamente. Além disso, a partir da base de dados, foram criadas novas variáveis, que representam os índices acumulados ao longo do tempo. Esse conjunto de variáveis foi relevante por ser capaz de demonstrar se as séries acumuladas exibem alguma tendência, indicando variações na pressão e temperatura do mar. A previsão do índice ONI de abril de 2024 a dezembro de 2024 foi utilizada para auxiliar a prever cenários futuros de velocidade do vento. As previsões sugeriram uma transição do *El Niño* para a *La Niña* em 2024, com uma queda brusca das anomalias do índice ONI. Primeiramente, foi feito um ajuste entre os dados observados de cada um dos índices e o ONI. Os resultados da regressão foram satisfatórios, com destaque para os índices Niño 3.4 e Niño 3. A partir disso, pode-se construir a previsão dos demais índices a partir do ONI.

Por fim, tal análise também mostrou que o fenômeno climático ENSO pode influenciar o comportamento da velocidade do vento nos locais em estudo como um todo, com destaque para *La Niña*.

Para obter os resultados finais foram utilizadas sete janelas de treinamento e validação neste trabalho. A primeira janela foi empregada com o objetivo de obter a melhor combinação dos parâmetros $p(v)$ e $m(v)$ para os modelos PARX e PARX-Cov, onde os parâmetros selecionados para cada estado e modelo serão aqueles que resultarem no menor erro. Esses parâmetros foram aplicados nas janelas 2 a 5 para calcular as métricas de desempenho. A partir desses resultados, foram escolhidos os melhores modelos para cada estado. Com a seleção dos melhores modelos concluída, o próximo passo foi aplicar esses modelos na janela 6, usando o ENSO previsto. Por fim na janela 7, foi realizada uma previsão de cenários futuros para 2024, também utilizando dados do ENSO *out-of-sample*, a partir dos melhores modelos.

Quando comparados com o modelo vigente (PAR), os modelos propostos demonstram um desempenho superior na modelagem das séries de velocidade do vento. Isso sugere que a inclusão de variáveis climáticas e da covariância exerce uma influência significativa na velocidade do vento dos estados brasileiros analisados, impactando diretamente na geração de energia do país. A partir da análise dos modelos, conclui-se que o PARX-Cov com o índice ONI Acumulado é o mais adequado para três estados, Pernambuco, Rio Grande do Sul e Santa Catarina, enquanto que o PARX-Cov com o índice SOI demonstra ser mais apropriado para o Rio Grande do Norte. Ademais, o modelo PARX com o índice ONI Acumulado é o mais indicado para os estados de Alagoas e Sergipe, já o PARX com Niño 4 Acumulado é o mais adequado para a Paraíba.

Como continuidade deste trabalho, propõe-se a aplicação de modelos estatísticos avançados para lidar com a parte não-linear das séries temporais de

velocidade do vento e para modelar a não-gaussianidade dos dados, frequentemente evidenciada por eventos extremos. Adicionalmente, é relevante expandir o estudo para incluir os demais estados do Nordeste, que também são grandes produtores de energia. A análise pode ser realizada para o subsistema Nordeste como um todo ou diferenciando entre as regiões do interior e do litoral. Por fim, sugere-se converter a velocidade do vento em estimativas de geração de energia. Em seguida, é interessante integrar a modelagem proposta em um programa de otimização da operação eletroenergética, como o PDDE ou o NEWAVE.

7

Referências Bibliográficas

- [1] EPE. <https://www.epe.gov.br/pt/publicacoes-dadosabertos/publicacoes/balanco-energetico-nacional-ben>, 2021. Acessado: 10-05-2023. 1.1
- [2] MENDES, L. F. R.. **Considerações acerca da geração hidroelétrica fluminense a partir da crise hídrica do estado de são paulo**. Boletim do Observatório Ambiental Alberto Ribeiro Lamego, 8(1):35–49, 2014. 1.1
- [3] MACEIRA, M.; MELO, A.; PESSANHA, J.; CRUZ, C.; ALMEIDA, V. ; JUSTINO, T.. **Wind uncertainty modeling in long-term operation planning of hydro-dominated systems**. In: 2022 17TH INTERNATIONAL CONFERENCE ON PROBABILISTIC METHODS APPLIED TO POWER SYSTEMS (PMAPS), p. 1–6. IEEE, 2022. 1.1, 6
- [4] MELO, G.; BARCELLOS, T.; RIBEIRO, R.; COUTO, R.; GUSMÃO, B.; OLIVEIRA, F. L. C.; MAÇAIRA, P.; FANZERES, B.; SOUZA, R. C. ; BET, O.. **Renewable energy sources spatio-temporal scenarios simulation under influence of climatic phenomena**. Electric Power Systems Research, 235:110725, 2024. 1.1
- [5] BURTON, T.; JENKINS, N.; SHARPE, D. ; BOSSANYI, E.. **Wind energy handbook**. John Wiley & Sons, 2011. 1.1
- [6] LIMA, A. R. D.; OTHERS. **Energia eólica e o meio ambiente: o estudo das implicações socioespaciais no alto sertão baiano**. 2020. 1.1
- [7] RAMADAN, H.. **Wind energy farm sizing and resource assessment for optimal energy yield in sinai peninsula, egypt**. Journal of Cleaner Production, 161:1283–1293, 2017. 1.1
- [8] COUNCIL, G. W. E.. **Global wind report 2021**. Global Wind Energy Council: Brussels, Belgium, p. 6–7, 2021. 1.1
- [9] IRENA. <https://www.irena.org/newsroom/pressreleases/2021/Apr/World-Adds-Record-New-Renewable-Energy-Capacity-in-2020>, 2021. Acessado: 10-05-2023. 1.1, 6
- [10] PINSON, P.. **Wind energy: Forecasting challenges for its operational management**. 2013. 1.1

- [11] FERREIRA, P. G. C.; OLIVEIRA, F. L. C. ; SOUZA, R. C.. **The stochastic effects on the brazilian electrical sector**. *Energy Economics*, 49:328–335, 2015. 1.1
- [12] SOUZA, R. C.; LUI, A.; DIAS, B. H.; OLIVEIRA, F. L. C. ; OTHERS. **Optimal operation of hydrothermal systems with hydrological scenario generation through bootstrap and periodic autoregressive models**. *European Journal of Operational Research*, 222(3):606–615, 2012. 1.1
- [13] NOAKES, D.; MCLEOD, A. ; HIPEL, K.. **Forecasting monthly riverflow time series**. *International Journal of Forecasting*, 1(2):179–190, 1985. 1.1
- [14] EPE. **Plano nacional de energia - pne 2050**. <https://static.poder360.com.br/2020/12/PNE2050.pdf>, 2018. Acessado: 20-05-2022. 1.1
- [15] DO NASCIMENTO CAMELO, H.; LUCIO, P. S.; JUNIOR, J. B. V. L. ; DE CARVALHO, P. C. M.. **A hybrid model based on time series models and neural network for forecasting wind speed in the brazilian northeast region**. *Sustainable Energy Technologies and Assessments*, 28:65–72, 2018. 1.1
- [16] DE MATTOS NETO, P. S.; DE OLIVEIRA, J. F.; JÚNIOR, D. S. D. O. S.; SIQUEIRA, H. V.; MARINHO, M. H. ; MADEIRO, F.. **An adaptive hybrid system using deep learning for wind speed forecasting**. *Information Sciences*, 581:495–514, 2021. 1.1
- [17] COUTO, R.; MAÇAIRA, P. ; CYRINO, F.. **Modelos de simulação estocástica de cenários de velocidade do vento com incorporação de variáveis climáticas**. 2023. 1.1
- [18] CORRÊA, C. S.; SCHUCH, D. A.; QUEIROZ, A. P. D.; FISCH, G.; CORRÊA, F. D. N. ; COUTINHO, M. M.. **The long-range memory and the fractal dimension: a case study for alcântara**. *Journal of Aerospace Technology and Management*, 9:461–468, 2017. 1.1, 2
- [19] LIMA, C. N. N.; FERNANDES, C. A. C.; FRANÇA, G. B. ; DE MATOS, G. G.. **Estimation of the el niño/la niña impact in the intensity of brazilian northeastern winds**. *Anuário do Instituto de Geociências*, 37(2):232–240. 1.1, 2
- [20] LOPES, R. F. C.; OTHERS. **Efeitos da tsm dos oceanos atlântico e pacífico tropicais sobre o vento no estado da paraíba**. 2022. 1.1, 2

- [21] ARPE, K.; MOLAVI-ARABSHAHI, M. ; LEROY, S. A. G.. **Wind variability over the caspian sea, its impact on caspian seawater level and link with enso**. *International Journal of Climatology*, 40(14):6039–6054, 2020. 1.1, 2
- [22] XU, Q.; LI, Y.; CHENG, Y.; YE, X. ; ZHANG, Z.. **Impacts of climate oscillation on offshore wind resources in china seas**. *Remote Sensing*, 14(8):1879, 2022. 1.1, 2
- [23] CORIA-MONTER, E.; SALAS DE LEÓN, D. A.; MONREAL-GÓMEZ, M. A. ; DURÁN-CAMPOS, E.. **Satellite observations of the effect of the “godzilla el niño” on the tehuantepec upwelling system in the mexican pacific**. *Helgoland Marine Research*, 73:1–11, 2019. 1.1, 2
- [24] MAÇAIRA, P. M. M.. **Modelos de Simulação Estocástica de Cenários de Vazão com Incorporação de Variáveis Climáticas**. PhD thesis, PUC-Rio, 2018. 1.1, 3.3.2
- [25] LUIZ-SILVA, W.; OSCAR-JÚNIOR, A. C.; CAVALCANTI, I. F. A. ; TREIST-MAN, F.. **An overview of precipitation climatology in brazil: space-time variability of frequency and intensity associated with atmospheric systems**. *Hydrological Sciences Journal*, 66(2):289–308, 2021. 1.1
- [26] MAÇAIRA, P.; THOMÉ, A.; CYRINO OLIVEIRA, F. ; DE ALMEIDA, F.. **Time series analysis with explanatory variables: A systematic literature review**. *Environmental Modelling & Software*, 107:199—209, 2018. 1.1
- [27] DE MENDONÇA, M. J. C.; PESSANHA, J. F. M.; DE ALMEIDA, V. A.; MEDRANO, L. A. T.; HUNT, J. D.; JUNIOR, A. O. P. ; NOGUEIRA, E. C.. **Synthetic wind speed time series generation by dynamic factor model**. *Renewable Energy*, 228:120591, 2024. 1.1
- [28] DURAN, M. J.; CROS, D. ; RIQUELME, J.. **Short-term wind power forecast based on arx models**. *Journal of Energy Engineering*, 133(3):172–180, 2007. 1.1
- [29] ASSUNÇÃO, G. H. O.. **Regressão espacial quantílica para previsão da velocidade do vento**. 2018. 1.1, 3.2.3
- [30] DE PAULA1 FERNANDO, D. L. P.; CARDOSO, A. C.; CARDOSO, R. B.; DE PAULA, G.; CUNHA, Q. ; VIEIRA, E. M.. **Modelagem espacial da**

- velocidade do vento a 50, 75 e 100 metros de altura para o estado de minas gerais, brasil, empregando geoestatística. *Revista Brasileira de Geografia Física*, 10(04):1281–1295, 2017. 1.1, 3.2.3
- [31] SANTOS, A. T. S. D.. **Um estudo sobre a variabilidade do vento no nordeste do brasil através de métodos estatísticos e via modelos dinâmicos de meso e micro escala.** 2014. 1.1, 3.2.3
- [32] IUNG, A. M.; CYRINO OLIVEIRA, F. L. ; MARCATO, A. L. M.. **A review on modeling variable renewable energy: complementarity and spatial–temporal dependence.** *Energies*, 16(3):1013, 2023. 1.1
- [33] DE SOUZA, N. B. P.; DOS SANTOS, J. V. C.; NASCIMENTO, E. G. S.; SANTOS, A. A. B. ; MOREIRA, D. M.. **Long-range correlations of the wind speed in a northeast region of brazil.** *Energy*, 243:122742, 2022. 2
- [34] CAVALCANTI, E. P.; SILVA, B. B. D.; SILVA, V. D. P. R. D. ; CHAVES FILHO, J. B.. **Wind speed variability and ocean influences: An approach for electrical energy generation purposes in northeastern brazil.** *Anuario do Instituto de Geociencias (Online)*, 43(2):273–285, 2020. 2
- [35] TORRES SILVA DOS SANTOS, A.; SANTOS E SILVA, C. M. ; OTHERS. **Seasonality, interannual variability, and linear tendency of wind speeds in the northeast brazil from 1986 to 2011.** *The Scientific World Journal*, 2013, 2013. 2
- [36] FRANCHITO, S. H.; ODA, T. O.; RAO, V. B. ; KAYANO, M. T.. **Interaction between coastal upwelling and local winds at cabo frio, brazil: an observational study.** *Journal of applied meteorology and climatology*, 47(6):1590–1598, 2008. 2
- [37] ENFIELD, D. B.; MAYER, D. A.. **Tropical atlantic sea surface temperature variability and its relation to el niño-southern oscillation.** *Journal of Geophysical Research: Oceans*, 102(C1):929–945, 1997. 2
- [38] RENKEN, J. S.; BROWN, C. L.; KENNEDY, G.; MAINGUY, J.; WERGELAS, N. ; LUPO, A. R.. **Using the daily change in the southern oscillation index to develop analogues and the relationship to severe weather outbreaks.** *International Journal of Climatology*, 42(16):8839–8853, 2022. 2

- [39] LI, X.; LI, Q.-P.; DING, Y.-H. ; WANG, M.. **Near-surface wind speed changes in eastern china during 1970–2019 winter and its possible causes.** *Advances in Climate Change Research*, 13(2):228–239, 2022. 2
- [40] BASTIDAS-SALAMANCA, M.; RUEDA-BAYONA, J. G.. **Effect of climate variability events over the colombian caribbean offshore wind resource.** *Water*, 13(22):3150, 2021. 2
- [41] DE AQUINO FERREIRA, S. C.; OLIVEIRA, F. L. C. ; MAÇAIRA, P. M.. **Validation of the representativeness of wind speed time series obtained from reanalysis data for brazilian territory.** *Energy*, 258:124746, 2022. 3.1
- [42] GONZALEZ-APARICIO, I.; MONFORTI, F.; VOLKER, P.; ZUCKER, A.; CARERI, F.; HULD, T. ; BADGER, J.. **Simulating european wind power generation applying statistical downscaling to reanalysis data.** *Applied Energy*, 199:155–168, 2017. 3.1
- [43] GRUBER, K.; KLÖCKL, C.; REGNER, P.; BAUMGARTNER, J. ; SCHMIDT, J.. **Assessing the global wind atlas and local measurements for bias correction of wind power generation simulated from merra-2 in brazil.** *Energy*, 189:116212, 2019. 3.1
- [44] GELARO, R.; MCCARTY, W.; SUÁREZ, M. J.; TODLING, R.; MOLOD, A.; TAKACS, L.; RANGLES, C. A.; DARMENOV, A.; BOSILOVICH, M. G.; REICHLER, R. ; OTHERS. **The modern-era retrospective analysis for research and applications, version 2 (merra-2).** *Journal of climate*, 30(14):5419–5454, 2017. 3.1
- [45] OLAUSON, J.; BERGKVIST, M.. **Modelling the swedish wind power production using merra reanalysis data.** *Renewable Energy*, 76:717–725, 2015. 3.1
- [46] RENEWABLES.NINJA. Disponível em: <https://www.renewables.ninja/>. Acesso em: 27 de Novembro de 2023, 2023. 3.1
- [47] PFENNINGER, S.; STAFFELL, I.. **Long-term patterns of european pv output using 30 years of validated hourly reanalysis and satellite data.** *Energy*, 114:1251–1265, 2016. 3.1
- [48] STAFFELL, I.; PFENNINGER, S.. **Using bias-corrected reanalysis to simulate current and future wind power output.** *Energy*, 114:1224–1239, 2016. 3.1

- [49] ATLAS, G. W.. Disponível em: <https://globalwindatlas.info/en>. Acesso em: 27 de Novembro de 2023, 2023. 3.1
- [50] NOAA. Disponível em: <https://www.ncei.noaa.gov/access/monitoring/enso/>. Acesso em: 31 de Março de 2024, 2024. 3.1, 4.2.2
- [51] NOAA. Disponível em: <https://www.cpc.ncep.noaa.gov/data/indices/>. Acesso em: 31 de Março de 2024, 2024. 3.1
- [52] INSTITUTE, I. R.. Disponível em: <https://iri.columbia.edu/our-expertise/climate/enso/>. Acesso em: 31 de Março de 2024, 2024. (document), 3.1, 4.2.2.2, 4.8, A.1
- [53] HIPEL, K.; MCLEOD, A.. **Time Series Modelling of Water Resources and Environmental Systems**. Elsevier, 1994. 3.2.1
- [54] MCLEOD, A.. **Diagnostic Checking Periodic Autoregression Models With Application**. *The Journal of Time Series Analysis*, 15:221–233, 1995. 3.2.1
- [55] SCHWARZ, G.. **Estimating the dimension of a model**. *Annals of Statistics*, 6:461–464, 1978. 3.2.1, 3.2.1
- [56] VRIEZE, S.. **Model selection and psychological theory: a discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC)**. *Psychological Methods*, 2012. 3.2.1
- [57] AKAIKE, H.. **A new look at the statistical model identification**. *IEEE Transactions on Automatic Control*, 19:716—723, 1974. 3.2.1
- [58] AHO, K.; DERRYBERRY, D. ; PETERSON, T.. **Model selection for ecologists: the worldviews of AIC and BIC**. *Ecology*, 95:631–636, 2014. 3.2.1
- [59] DISMUKE, C.; LINDROOTH, R.. **Ordinary least squares**. *Methods and designs for outcomes research*, 93(1):93–104, 2006. 3.2.1
- [60] URSU, E.; PEREAU, J.. **Estimation and identification of periodic autoregressive models with one exogenous variable**. *Journal of the Korean Statistical Society*, 46:629–640, 2017. 3.2.2, 3.2.2
- [61] SILVEIRA, C.; ALEXANDRE, A.; DE SOUZA FILHO, F.; VASCONCELOS JUNIOR, F. ; CABRAL, S.. **Monthly streamflow forecast for National**

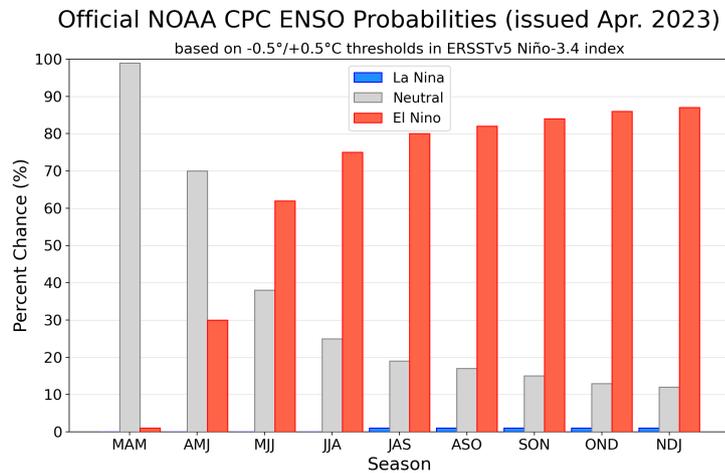
- Interconnected System (NIS) using Periodic Auto-regressive Endogenous Models (PAR) and Exogenous (PARX) with climate information.** *Brazilian Journal of Water Resources*, 22, 2017. 3.2.2
- [62] DA SILVA, R. N.; FANTINI, D. G.; MENDES, R. C. F. ; JUNIOR, A. C. P. B.. **Previsão de velocidade do vento com sériel temporal multivariada utilizando rede neural recorrente.** In: CONGRESSO BRASILEIRO DE ENERGIA SOLAR-CBENS, p. 1–9, 2022. 3.3.1
- [63] MIGUEL, P.. **Gestão de um sistema fotovoltaico em instalação trifásica utilizando técnicas de machine learning.** 2020. 3.3.1
- [64] CYRINO OLIVEIRA, F.. **Nova abordagem para geração de cenários de afluências no planejamento da operação energética de médio prazo.** Dissertação de mestrado, PUC-Rio, 2010. 3.3.2
- [65] MELO, A.; MACEIRA, M. E. P.; PESSANHA, J. F. ; JUSTINO, T. C.. **Distribuições weibull tri-paramétricas para a geração de cenários de velocidades mensais de ventos correlacionadas com vazões aos reservatórios.** 2022. 3.3.2
- [66] CHARBENEAU, R.. **Comparison of the two- and three-parameter log normal distributions used in streamflow synthesis.** *Water Resources Research*, 14:149–150, 1978. 3.3.2
- [67] PEREIRA, M.; G, O.; COSTA, C. ; KELMAN, J.. **Stochastic streamflow models for hydroelectric systems.** *Water Resources Research*, 20:379–390, 1984. 3.3.2
- [68] CYRINO OLIVEIRA, F.; CASTRO SOUZA, R. ; COSTA FERREIRA, P.. **A time series model for building scenarios trees applied to stochastic optimisation.** *Mathematical Problems in Engineering*, 2014, 2014. 3.3.2
- [69] R CORE TEAM. **R: A Language and Environment for Statistical Computing.** R Foundation for Statistical Computing, Vienna, Austria, 2022. 4
- [70] SAID, S.; D, D.. **Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order.** *Biometrika*, 71:599–607, 1984. 4.1
- [71] PERRON, P.. **Trends and random walks in macroeconomic time series.** *Journal of Economic Dynamics and Control*, 12:297–332, 1988. 4.1

- [72] BJERKNES, J.. **Atmospheric teleconnections from the equatorial Pacific**. *Journal of Physical Oceanography*, 97:163–172, 1969. 4.2.1, 4.2.2
- [73] NOAA. Disponível em: <https://www.climate.gov/news-features/blogs/enso/walker-circulation-ensos-atmospheric-buddy>. Acesso em: 27 de Novembro de 2023, 2023. (document), 4.3
- [74] OLIVEIRA, J.. **O El Niño e Você - o fenômeno climático** . Transtec, mar 2001. 4.2.1
- [75] NOAA. Disponível em: <https://www.noaa.gov/>. Acesso em: 27 de Novembro de 2023, 2023. 4.2.1
- [76] NOAA. Disponível em: <https://www.climate.gov/news-features/blogs/enso/why-are-there-so-many-enso-indexes-instead-just-one>. Acesso em: 27 de Novembro de 2023, 2023. (document), 4.2.2, 4.4, 4.5
- [77] BARNSTON, A.; CHELLIAH, M. ; GOLDENBERG, S.. **Documentation of a highly ENSO-related SST region in the equatorial Pacific**. *Atmosphere-Ocean*, 35:367–383, 1997. 4.2.2
- [78] WEISBERG, S.. **Applied linear regression**, volumen 528. John Wiley & Sons, 2005. 4.2.2.2
- [79] KRUSKAL, W. H.; WALLIS, W. A.. **Use of ranks in one-criterion variance analysis**. *Journal of the American statistical Association*, 47(260):583–621, 1952. 4.3

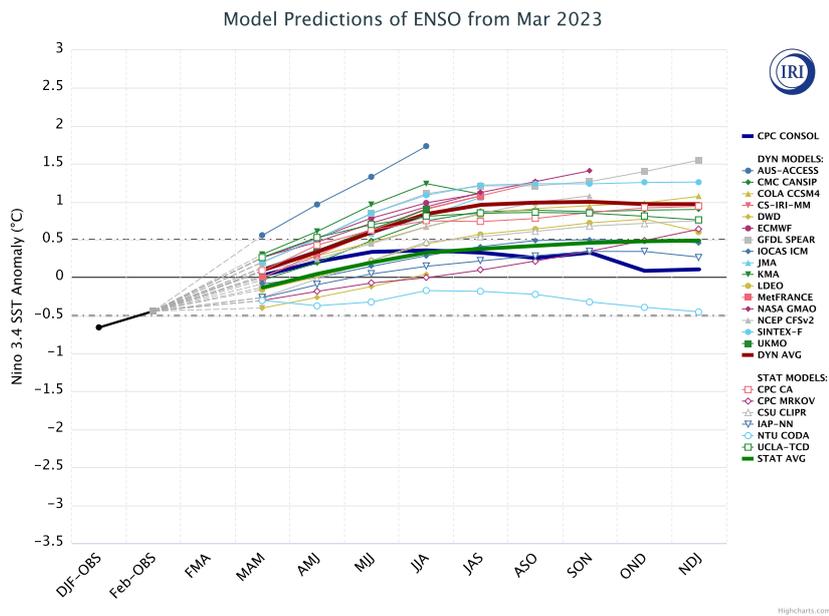
A

Apêndice - Ajuste ENSO 2023

Esse Apêndice apresenta o panorâma e os procedimentos feitos para os dados de previsão do ENSO pro período de abril de 2023 a dezembro de 2023.



(a) Probabilidades de Fases



(b) Anomalias

Figura A.1: Previsões da Probabilidades de fases e de Anomalias do ENSO - 2023.
Fonte: [52].

Tabela A.1: Ajuste dos Índices do ENSO ao ONI - 2023. Fonte: Elaborado pelo autor.

Índice	Coefficientes	Valor Estimado	Desvio Padrão	P-valor	R ²
SOI	(Intercepto)	0,264	0,036	≈ 0	0,534
	ONI	-1,375	0,044	≈ 0	
SOI Equatorial	(Intercepto)	-0,002	0,017	0,892	0,7
	ONI	-0,918	0,02	≈ 0	
Niño 1+2	(Intercepto)	-0,06	0,025	0,017	0,436
	ONI	0,792	0,03	≈ 0	
Niño 3	(Intercepto)	-0,053	0,011	≈ 0	0,826
	ONI	0,887	0,014	≈ 0	
Niño 4	(Intercepto)	-0,073	0,011	≈ 0	0,785
	ONI	0,725	0,013	≈ 0	
Niño 3.4	(Intercepto)	-0,056	0,009	≈ 0	0,878
	ONI	0,829	0,01	≈ 0	

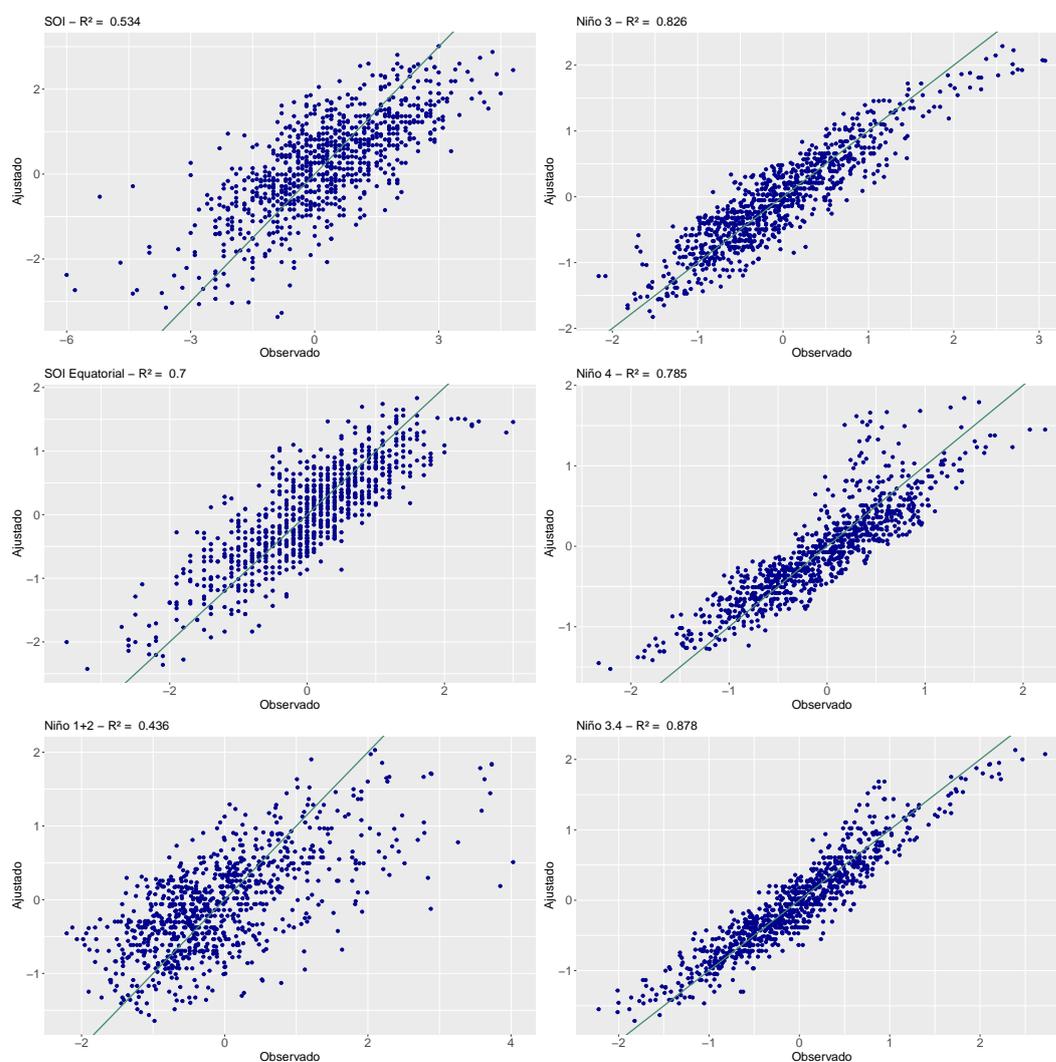


Figura A.2: Gráficos de Dispersão dos Valores Observados x Ajustados dos Índices - 2023. Fonte: Elaborado pelo autor.

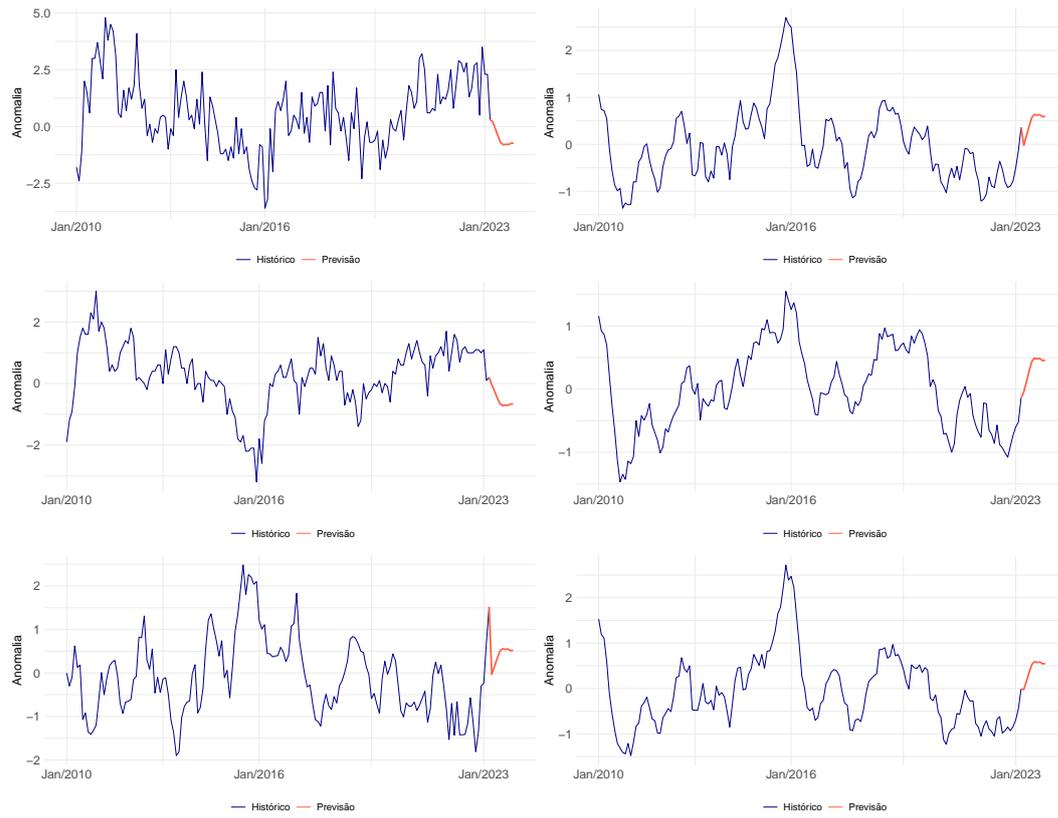


Figura A.3: Previsão dos Índices ENSO - 2023. Fonte: Elaborado pelo autor.

B

Apêndice - Métricas MAE e R^2

Esse Apêndice mostra os gráficos de erro e ajuste das métricas MAE e R^2 , respectivamente, para o resultado da modelagem das janelas 2 a 5.

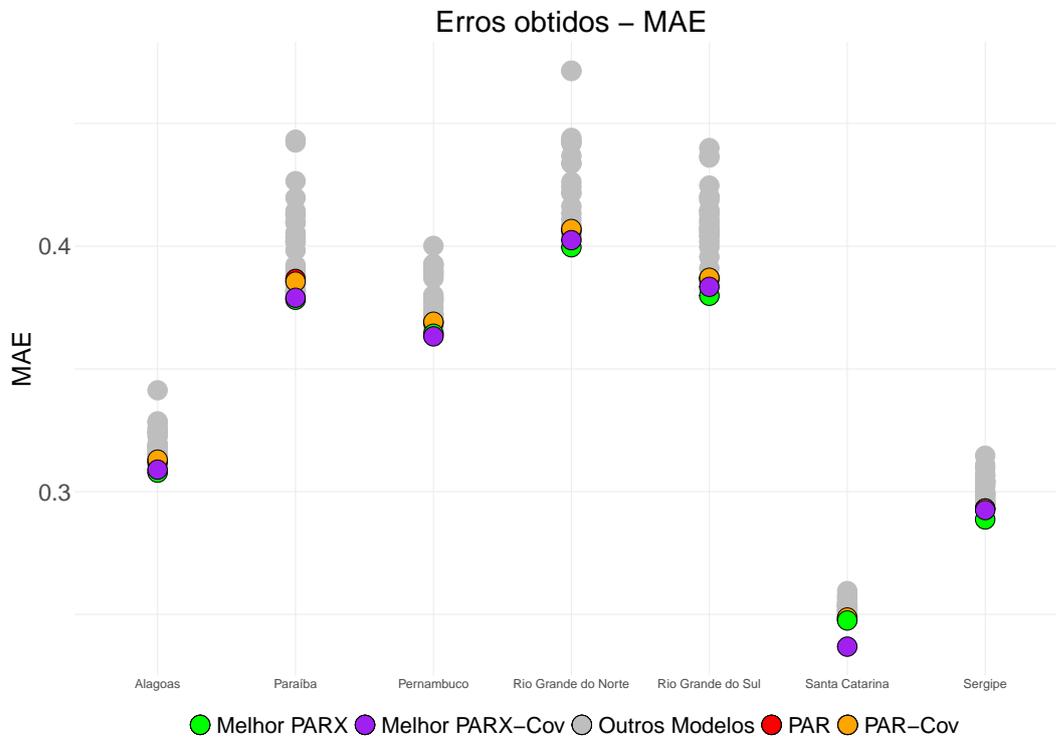


Figura B.1: MAE obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.

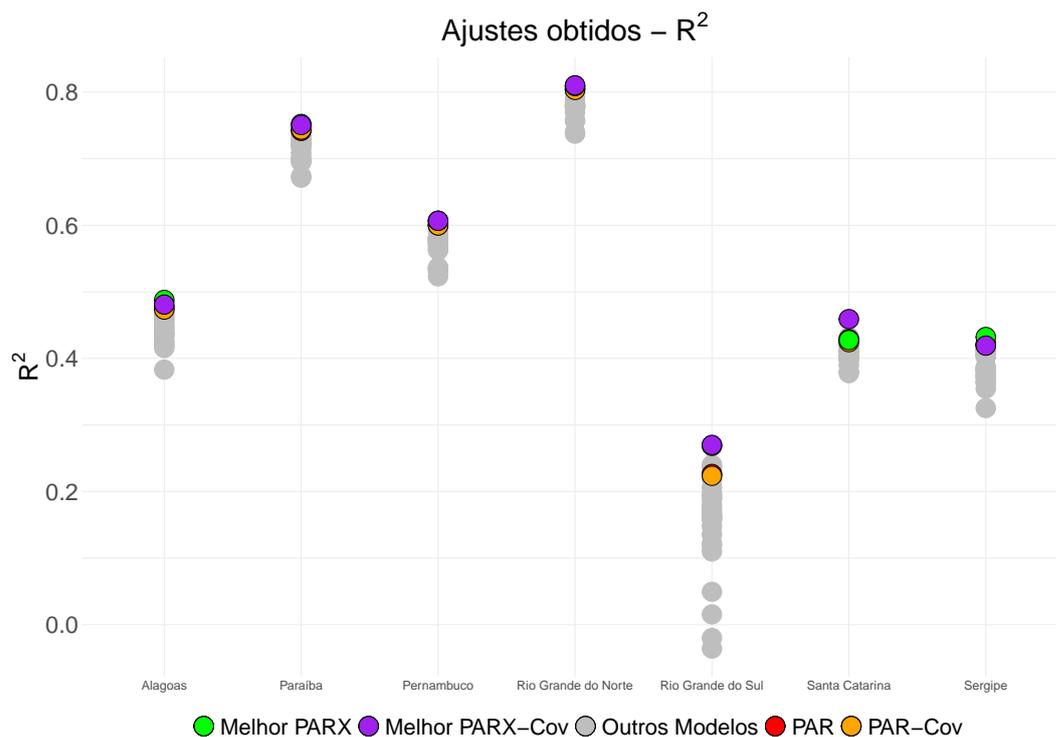


Figura B.2: R^2 obtido para todos os 30 modelos (cinza) nas janelas 2 a 5, com o melhor modelo PARX-Cov que usa um índice ENSO (roxo), o melhor modelo PARX que usa um índice ENSO (verde), o PAR-Cov (laranja) e o PAR (vermelho) para cada estado. Fonte: Elaborado pelo autor.