

UFRRJ
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
MODELAGEM MATEMÁTICA E COMPUTACIONAL

DISSERTAÇÃO

UM ESTUDO SOBRE AS ABORDAGENS DE
SÉRIES TEMPORAIS HIERÁRQUICAS PARA
PREVISÃO DO CONSUMO DE ENERGIA
ELÉTRICA DO SETOR INDUSTRIAL
BRASILEIRO

Marlon Mesquita Lopes Cabreira

2023



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL**

**UM ESTUDO SOBRE AS ABORDAGENS DE SÉRIES TEMPORAIS
HIERÁRQUICAS PARA PREVISÃO DO CONSUMO DE ENERGIA
ELÉTRICA DO SETOR INDUSTRIAL BRASILEIRO**

MARLON MESQUITA LOPES CABREIRA

Sob orientação de
Felipe Leite Coelho da Silva

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre** no Programa de Pós-Graduação em Modelagem Matemática e Computacional, Área de Concentração em Modelagem Matemática e Computacional.

Seropédica, RJ, Brasil
Dezembro de 2023

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

MC117e
e Mesquita Lopes Cabreira, Marlon , 22/08/1995-
UM ESTUDO SOBRE AS ABORDAGENS DE SÉRIES TEMPORAIS
HIERÁRQUICAS PARA PREVISÃO DO CONSUMO DE ENERGIA
ELÉTRICA DO SETOR INDUSTRIAL BRASILEIRO / Marlon
Mesquita Lopes Cabreira. - Seropédica, 2023.
153 f.

Orientador: Felipe Leite Coelho da Silva.
Dissertação(Mestrado). -- Universidade Federal Rural
do Rio de Janeiro, Programa de Pós-Graduação em
Modelagem Matemática e Computacional, 2023.

1. Previsão. 2. Séries Temporais Hierárquicas. 3.
Energia Elétrica. I. Leite Coelho da Silva, Felipe ,
28/05/1981-, orient. II Universidade Federal Rural do
Rio de Janeiro. Programa de Pós-Graduação em Modelagem
Matemática e Computacional III. Título.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE CIÊNCIAS EXATAS



PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

Seropédica-RJ, 11 de dezembro de 2023.

MARLON MESQUITA LOPES CABREIRA

Dissertação submetida como requisito parcial para a obtenção de grau de **Mestre**, no Programa de Pós-Graduação em Modelagem Matemática e Computacional PPGMMC, área de Concentração em Modelagem Matemática e Computacional.

DISSERTAÇÃO APROVADA EM 11/12/2023

Felipe Leite Coelho da Silva Drº UFRRJ (Orientador, Presidente da Banca)

Carlos Andres Reyna Vera-Tudela Drº UFRRJ (membro interno)

Fernando Luiz Cyrino Oliveira Drº (PUC-RJ) (externo à Instituição)



Emitido em 11/12/2023

ATA N° ata/2023 - ICE (12.28.01.23)
(N° do Documento: 6050)

(N° do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 13/12/2023 14:08)
CARLOS ANDRES REYNA VERA TUDELA
PROFESSOR DO MAGISTERIO SUPERIOR
DeptM (12.28.01.00.00.63)
Matrícula: ###336#3

(Assinado digitalmente em 13/12/2023 15:01)
FELIPE LEITE COELHO DA SILVA
PROFESSOR DO MAGISTERIO SUPERIOR
DeptM (12.28.01.00.00.63)
Matrícula: ###398#2

(Assinado digitalmente em 13/12/2023 15:14)
FERNANDO LUIZ CYRINO OLIVEIRA
ASSINANTE EXTERNO
CPF: ###.###.726-##

Visualize o documento original em <https://sipac.ufrrj.br/documentos/> informando seu número: **6050**, ano: **2023**, tipo: **ATA**, data de emissão: **13/12/2023** e o código de verificação: **b963a3034e**

Agradecimentos

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

Agradeço a Deus, por me abençoar em toda minha vida e por conceder a mim e à minha família saúde e paz.

Aos meus pais, Marcelo e Rosângela, pelo amor incondicional que me fez ser um homem sensível e bondoso, além de me educarem e me instruírem, principalmente com valores de justiça social. Vocês são exemplos para mim. Meus pais entregaram a vaidade deles para os filhos, isso é uma prova de amor incrível e vou lembrar disso por toda a minha vida.

A minha irmã, Marília, pelo seu companheirismo e seu amor. Sua presença me faz o irmão mais feliz do mundo. Você é muito importante para mim.

A minha avó, Maria da Conceição, pelo seu carinho e por realizar um importante papel na minha educação, cuidando de mim quando meus pais estavam no trabalho.

Ao meu tio Moacir, por me ajudar na trajetória do mestrado e seu incentivo que me fizeram acreditar cada vez mais em mim. E desde já deixo um abraço a todas as pessoas da minha família.

A todos os professores do mestrado PPGMMC-UFRRJ pelas aulas, pesquisas e viagens e aos professores da UFRRJ que me orientaram em diversos projetos, em especial meu orientador Felipe, muito obrigado por compartilhar seus conhecimentos comigo e sua paciência e companheirismo. Além disso, agradeço a professora Josiane pela parceria em artigos em séries temporais.

A minha querida, Emily, pelo seu carinho e amor. Agradeço a Deus todos os dias por ter te conhecido.

As minhas amigas Lais, Paula, Ana, Camila e Maria, vocês me fazem ter a certeza que sou abençoado por Deus. Amo vocês!

Ao Matheus Henrique, que me incentivou a cursar matemática e vir para a UFRRJ, sendo assim, participante ativo da melhor decisão profissional da minha vida. Ao doutor Gabriel Bittencourt, que me ajudou na escolha do curso de graduação e pelas cervejas nos fins de semana, além disso, quero lembrar que me deve uma cerveja na orla da praia. Ao Marlon pelo companheirismo e hospitalidade em Volta Redonda. A Paloma pela sua amizade e me ajudar na minha trajetória quando eu precisava.

A minha república "Casa Comigo?" cujo os integrantes são: Rafael, Matheus, Isa e Nath, meu muito obrigado, pelo carinho, companheirismo e pelas resenhas. Em especial, agradeço ao Rafael pela parceria nos artigos de séries temporais e aos meus queridos amigos Edu, Júlio e Betoni, vocês são pessoas incríveis!

Por fim, amo todos vocês!

*"Uma mente que se abre a uma nova
ideia jamais volta ao seu tamanho
original." Albert Einstein*

MESQUITA LOPES CABREIRA, Marlon. **UM ESTUDO SOBRE AS ABORDAGENS DE SÉRIES TEMPORAIS HIERÁRQUICAS PARA PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA DO SETOR INDUSTRIAL BRASILEIRO**. 2023. 132f. Dissertação (Mestrado em Modelagem Matemática e Computacional). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2023.

O setor industrial brasileiro é o maior consumidor de energia elétrica e, portanto, o planejamento energético torna-se muito importante, principalmente devido ao impacto econômico, social e ambiental. Neste contexto, as análises e projeções consumo de energia elétrica tornam-se ferramentas úteis para a tomada de decisões. No setor industrial, o consumo de energia elétrica pode ser organizado em uma estrutura hierárquica composta por cada região geográfica (Sul, Sudeste, Centro-Oeste, Nordeste e Norte) e seus respectivos estados. O objetivo deste trabalho é analisar e avaliar a capacidade preditiva das abordagens *bottom-up*, *top-down*, combinação ótima e híbrida utilizadas para prever o consumo de energia elétrica no setor industrial brasileiro. A abordagem híbrida proposta neste trabalho combina as abordagens *bottom-up* e *top-down*. Essas abordagens incorporaram as projeções obtidas através dos métodos preditivos de suavização exponencial e de Box e Jenkins. Além disso, foi apresentada uma análise exploratória para as séries temporais de consumo de energia elétrica do setor industrial para o Brasil, regiões e estados. Os resultados indicam que a abordagem híbrida proposta pode contribuir para a análise e projeção do consumo de energia elétrica no setor industrial. A capacidade preditiva das abordagens foi avaliada pelas métricas MAPE e RMSE.

Palavras-chave: Previsão, Séries Temporais Hierárquicas, Energia Elétrica.

ABSTRACT

MESQUITA LOPES CABREIRA, Marlon. **A STUDY ON HIERARCHICAL TIME SERIES APPROACHES FOR FORECASTING ELECTRIC ENERGY CONSUMPTION IN THE BRAZILIAN INDUSTRIAL SECTOR**. 2023. 132p. Dissertation (Master in Mathematical and Computational Modeling). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2023.

The Brazilian industrial sector is the largest consumer of electrical energy and, therefore, energy planning becomes very important, mainly due to the economic, social and environmental impact. In this context, analyzes and projections of electrical energy consumption become useful tools for decision-making. In the industrial sector, electrical energy consumption can be organized in a hierarchical structure composed of each geographic region (South, Southeast, Central-West, Northeast and North) and their respective states. The objective of this work is to analyze and evaluate the predictive capacity of the *bottom-up*, *top-down*, optimal and hybrid combination approaches used to predict electrical energy consumption in the Brazilian industrial sector. The hybrid approach proposed in this work combines the *bottom-up* and *top-down* approaches. These approaches incorporated projections obtained through exponential smoothing and Box and Jenkins predictive methods. Furthermore, an exploratory analysis was presented for the time series of electrical energy consumption in the industrial sector for Brazil, regions and states. The results indicate that the proposed hybrid approach can contribute to the analysis and projection of electrical energy consumption in the industrial sector. The predictive capacity of the approaches was evaluated using the MAPE and RMSE metrics.

Keywords: Forecasting, Hierarchical Time Series, Electricity .

1	INTRODUÇÃO	1
1.1	Motivação	1
1.2	Objetivo	2
1.3	Organização da Dissertação	2
2	REVISÃO BIBLIOGRÁFICA	4
3	REVISÃO TEÓRICA	6
3.1	Séries Temporais	6
3.1.1	Tendência e Sazonalidade	6
3.1.2	Estacionalidade e Diferenciação	6
3.1.3	Autocorrelação	8
3.1.4	Capacidade Preditiva dos Modelos de Séries Temporais	9
3.2	Modelos de Suavização Exponencial	9
3.2.1	Método de Suavização Exponencial	10
3.2.2	Modelos de Suavização Exponencial Simples	10
3.2.3	Modelos Holt-Winters com Tendência	11
3.2.4	Modelos Holt-Winters Sazonal Aditivo	12
3.2.5	Modelos Holt-Winters com Tendência e Sazonalidade Aditiva	12
3.2.6	Modelos Holt-Winters Sazonal Multiplicativo	13
3.2.7	Modelos Holt-Winters com Tendência Aditiva e Sazonalidade Multiplicativa	13
3.2.8	Modelos Holt-Winters Amortecido	14
3.2.9	Modelos Holt-Winters Amortecido com Sazonalidade Aditiva	14
3.2.10	Modelo Holt-Winters Amortecido com Sazonalidade Multiplicativa	14
3.2.11	Classificação Bidirecional de Modelos Holt-Winters	15
3.3	Modelos de Box e Jenkins	17
3.3.1	Modelos Autorregressivos (AR)	17
3.3.2	Modelos de Médias Móveis	17
3.3.3	Modelos ARIMA	17
3.3.4	Modelos SARIMA	18
3.4	Avaliação dos Modelos Preditivos	20
3.5	Séries Temporais Hierárquicas	21
3.6	Abordagens de Previsão Hierárquica	23

3.6.1	A Abordagem <i>Bottom-up</i>	23
3.6.2	A Abordagem <i>Top-Down</i>	23
3.6.3	A Abordagem de Combinação Ótima	24
4	MATERIAIS E MÉTODOS	26
4.1	Materiais	26
4.2	Metodologia	26
4.2.1	Etapas de comparação das abordagens	27
4.2.2	Abordagem híbrida proposta	28
5	ANÁLISE EXPLORATÓRIA DOS DADOS	30
5.1	Brasil e Regiões	30
5.2	Região Norte	40
5.3	Região Nordeste	48
5.4	Região Centro-Oeste	57
5.5	Região Sudeste	62
5.6	Região Sul	67
6	RESULTADOS E DISCUSSÕES	72
6.1	Modelos de Suavização Exponencial	72
6.2	Modelos de Box e Jenkins	78
6.3	Comparações entre as Abordagens em Séries Temporais Hierárquicas	83
6.3.1	Hierarquia Brasil-Regiões	84
6.3.2	Hierarquia Brasil-Regiões-Estados	87
7	CONCLUSÕES	91
8	REFERÊNCIAS BIBLIOGRÁFICAS	93
9	ANEXO I	98
9.1	Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Norte	98
9.2	Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Nordeste	103
9.3	Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Centro-Oeste	109
9.4	Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Sudeste	111
9.5	Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Sul	114
9.6	Previsão para a Hierarquia Brasil-Regiões-Estados	116
9.7	Hierarquia Regiões-Estados	118

Lista de Figuras

Figura 1.1 – Esquema hierárquico de dois níveis contendo a série nacional, regionais e estados.....	2
Figura 3.1 – Autocorrelação da série temporal do consumo de energia elétrica do setor industrial brasileiro.	8
Figura 3.2 – (a) Série temporal mensal que registra o total de passageiros internacionais (em milhares) da linha aérea (Pan Am) no período de janeiro de 1949 à dezembro 1960, nos EUA. (b) Este conjunto de dados contém observações sobre a concentração de dióxido de carbono (CO_2) na atmosfera feitas em Mauna Loa de Janeiro de 1959 à Dezembro de 1998.	10
Figura 3.3 – Aplicação de uma diferença sazonal na série dos dados de consumo de energia elétrica do setor industrial brasileiro.....	19
Figura 3.4 – Aplicação de uma dupla diferenciação na série dos dados de consumo de energia elétrica do setor industrial brasileiro.....	19
Figura 3.5 – Gráfico contendo a série temporal, a função de autocorrelação dos resíduos e a distribuição dos resíduos para o modelo SARIMA(0, 1, 0)(0, 1, 2) ₁₂	20
Figura 3.6 – Série temporal hierárquica de dois níveis.....	21
Figura 4.1 – Fluxograma com as etapas da metodologia.	26
Figura 4.2 – Fluxograma com as etapas da metodologia da abordagem híbrida.	29
Figura 5.1 – Box-plot dos dados do consumo de energia elétrica do setor industrial brasileiro por ano.	31
Figura 5.2 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Norte.	32
Figura 5.3 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Nordeste.	33
Figura 5.4 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Centro-Oeste.....	34
Figura 5.5 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Sudeste.	36
Figura 5.6 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Sul.....	37
Figura 5.7 – (a) Séries temporais do consumo do setor industrial brasileiro e regiões. (b) Séries temporais do consumo do setor industrial das regiões Sul, Nordeste, Centro-Oeste e Norte.	38

Figura 5.8 – Box-plot dos dados mensal do consumo de energia elétrica do setor industrial: (a) brasileiro; (b) da região Norte; (c) da região Nordeste; (d) da região Centro-Oeste; (e) da região Sudeste; (f) da região Sul.	38
Figura 5.9 – Gráfico de dispersão entre os dados de consumo de energia elétrica do setor industrial brasileiro e suas respectivas regiões.	40
Figura 5.10 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Acre.	41
Figura 5.11 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Amazonas.	42
Figura 5.12 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Rondônia.	42
Figura 5.13 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Roraima.	43
Figura 5.14 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Pará.	43
Figura 5.15 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Amapá.	44
Figura 5.16 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Tocantins.	45
Figura 5.17 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Norte e seus estados.	45
Figura 5.18 – (a) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de seis estados da região Norte. (b) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de três estados da região Norte.	46
Figura 5.19 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Norte; (b) do Acre; (c) do Amapá; (d) do Amazonas.	47
Figura 5.20 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) de Rondônia; (b) de Roraima; (c) do Pará; (d) do Tocantins.	47
Figura 5.21 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Alagoas.	49
Figura 5.22 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Bahia.	50
Figura 5.23 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Ceará.	51
Figura 5.24 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Maranhão.	51
Figura 5.25 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio Grande do Norte.	52
Figura 5.26 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Sergipe.	53
Figura 5.27 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Paraíba.	53
Figura 5.28 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Pernambuco.	54
Figura 5.29 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Piauí.	55

Figura 5.30 – (a) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Nordeste e seus estados. (b) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de sete estados da região Norte.	55
Figura 5.31 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Nordeste; (b) do Alagoas; (c) da Bahia; (d) do Ceará.	56
Figura 5.32 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) do Maranhão; (b) do Rio Grande do Norte; (c) do Sergipe; (d) da Paraíba; (e) de Pernambuco; (f) do Piauí.	56
Figura 5.33 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Mato Grosso.	58
Figura 5.34 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Mato Grosso do Sul.	59
Figura 5.35 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Goiás.	60
Figura 5.36 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Distrito Federal.	60
Figura 5.37 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus estados.	61
Figura 5.38 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Centro-Oeste; (b) de Goiás; (c) do Mato Grosso; (d) do Mato Grosso do Sul; (e) do Distrito Federal.	62
Figura 5.39 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de São Paulo.	63
Figura 5.40 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Minas Gerais.	64
Figura 5.41 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Espírito Santo.	65
Figura 5.42 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio de Janeiro.	65
Figura 5.43 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Sudeste e seus estados.	66
Figura 5.44 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Sudeste; (b) de São Paulo; (c) de Minas Gerais; (d) do Espírito Santo; (e) do Rio de Janeiro.	67
Figura 5.45 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Paraná.	68
Figura 5.46 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Santa Catarina.	69
Figura 5.47 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio Grande do Sul.	70
Figura 5.48 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Sul e seus estados.	70
Figura 5.49 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Sul; (b) do Paraná; (c) de Santa Catarina; (d) do Rio Grande do Sul.	71
Figura 6.1 – Esquema hierárquico de um nível Brasil e Regiões.	84

Figura 6.2 – (a) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de suavização exponencial para a hierarquia de um nível. (b) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de Box e Jenkins para a hierarquia de um nível.....	86
Figura 6.3 – (a) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de suavização exponencial para a hierarquia de um nível. (b) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de Box e Jenkins para a hierarquia de um nível.....	87
Figura 6.4 – (a) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de suavização exponencial para a hierarquia de dois níveis. (b) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de Box e Jenkins para a hierarquia de dois níveis.....	89
Figura 6.5 – (a) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de suavização exponencial para a hierarquia de dois níveis. (b) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de Box e Jenkins para a hierarquia de dois níveis.....	90
Figura 9.1 – Comparação das previsões das duas quatro abordagens para a hierarquia de dois níveis do consumo de energia elétrica do setor industrial brasileiro utilizando o método preditivo de suavização exponencial.	117
Figura 9.2 – Comparação das previsões das duas quatro abordagens para a hierarquia de dois níveis do consumo de energia elétrica do setor industrial brasileiro utilizando o método preditivo de Box e Jenkins.	118

Lista de Tabelas

Tabela 3.1 – Tabela contendo a classificação bidirecional dos modelos de suavização exponencial.	15
Tabela 3.2 – Tabela contendo a associação de métodos de suavização exponencial com a classificação bidirecional (T, S).	16
Tabela 4.1 – Quantidade total e por nível de séries temporais na hierarquia.	27
Tabela 4.2 – Notações das séries temporais que compõe a hierarquia.	28
Tabela 5.1 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial brasileiro em GWh.	30
Tabela 5.2 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Norte em GWh.	32
Tabela 5.3 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Nordeste em GWh.	33
Tabela 5.4 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Centro-Oeste em GWh.	34
Tabela 5.5 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Sudeste em GWh.	35
Tabela 5.6 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Sul em GWh.	36
Tabela 5.7 – Tabela contendo o nível de correlação entre os dados nacionais e regionais de consumo de energia elétrica do setor industrial.	39
Tabela 5.8 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Norte em GWh para o ano de 2019.	40
Tabela 5.9 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Norte em GWh para o ano de 2020.	41
Tabela 5.10 – Tabela contendo o nível de correlação entre os dados da região Norte e seus estados de consumo de energia elétrica do setor industrial.	48
Tabela 5.11 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Nordeste em GWh para o ano de 2019.	48
Tabela 5.12 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Nordeste em GWh para o ano de 2020.	49

Tabela 5.13 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados.	57
Tabela 5.14 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste em GWh para o ano de 2019.	58
Tabela 5.15 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste em GWh para o ano de 2020.	58
Tabela 5.16 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus estados.	62
Tabela 5.17 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sudeste em GWh para o ano de 2019.	63
Tabela 5.18 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sudeste em GWh para o ano de 2020.	63
Tabela 5.19 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Sudeste e seus estados.	67
Tabela 5.20 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sul em GWh para o ano de 2019. ...	68
Tabela 5.21 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sul em GWh para o ano de 2020. ...	68
Tabela 5.22 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Sul e seus estados.	71
Tabela 6.1 – Tabela contendo o tipo de modelo de suavização exponencial das séries de nível Brasil e regionais.	72
Tabela 6.2 – Tabela contendo as métricas MAPE e RMSE dos modelos suavização exponencial dos dados Nacionais e Regionais	73
Tabela 6.3 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Norte.	73
Tabela 6.4 – Tabela contendo as métricas MAPE e RMSE dos modelos de suavização exponencial das séries dos estados da região Norte.	74
Tabela 6.5 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Nordeste.	74
Tabela 6.6 – Tabela contendo as métricas MAPE e RMSE dos modelos de suavização exponencial das séries dos estados da região Nordeste	75
Tabela 6.7 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Centro-Oeste.	75
Tabela 6.8 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Centro-Oeste.	76
Tabela 6.9 – Tabela contendo o tipo de modelo Holt-Winters das séries dos estados da região Sudeste.	76
Tabela 6.10 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Sudeste.	76
Tabela 6.11 – Tabela contendo o tipo de modelo Holt-Winters das séries dos estados da região Sul.	77
Tabela 6.12 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Sul.	77
Tabela 6.13 – Tabela com o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries de nível Brasil e regionais.	78

Tabela 6.14 – Tabela com as métricas MAPE e RMSE dos modelos SARIMA dos dados nacionais e regionais.....	78
Tabela 6.15 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Norte.	79
Tabela 6.16 – Tabela com as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Norte	79
Tabela 6.17 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Nordeste.	80
Tabela 6.18 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Nordeste	80
Tabela 6.19 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Centro-Oeste.	81
Tabela 6.20 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Centro-Oeste.....	81
Tabela 6.21 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Sudeste.	82
Tabela 6.22 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Sudeste.....	82
Tabela 6.23 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Sul.....	83
Tabela 6.24 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q) ₁₂ das séries dos estados da região Sul.	83
Tabela 6.25 – Tabela das métricas MAPE e RMSE para os dados do Brasil e regiões utilizando o método de suavização exponencial.	84
Tabela 6.26 – Tabela das métricas MAPE e RMSE para os dados do Brasil e regiões utilizando o método de Box e Jenkins.	85
Tabela 6.27 – Tabela das métricas MAPE e RMSE para os dados de consumo de energia elétrica do setor industrial brasileiro utilizando o método de suavização exponencial na hierarquia de dois níveis.....	87
Tabela 6.28 – Tabela das métricas MAPE e RMSE para os dados de consumo de energia elétrica do setor industrial brasileiro utilizando o método de Box e Jenkins na hierarquia de dois níveis.	88
Tabela 9.1 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Acre em GWh.	98
Tabela 9.2 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Amazonas em GWh.	99
Tabela 9.3 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Rondônia em GWh.	99
Tabela 9.4 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Roraima em GWh.	100
Tabela 9.5 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Pará em GWh.....	101
Tabela 9.6 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Amapá em GWh.....	101
Tabela 9.7 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Tocantins em GWh.	102
Tabela 9.8 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Alagoas em GWh.	103

Tabela 9.9 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Bahia em GWh.	103
Tabela 9.10 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Ceará em GWh.	104
Tabela 9.11 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Maranhão em GWh.	105
Tabela 9.12 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio Grande do Norte em GWh.	105
Tabela 9.13 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Sergipe em GWh.	106
Tabela 9.14 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado da Paraíba em GWh.	107
Tabela 9.15 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Pernambuco em GWh.	107
Tabela 9.16 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Piauí em GWh.	108
Tabela 9.17 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Mato Grosso em GWh.	109
Tabela 9.18 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Mato Grosso do Sul em GWh.	109
Tabela 9.19 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Goiás em GWh.	110
Tabela 9.20 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Distrito Federal em GWh.	111
Tabela 9.21 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de São Paulo em GWh.	111
Tabela 9.22 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Minas Gerais em GWh.	112
Tabela 9.23 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Espírito Santo em GWh.	113
Tabela 9.24 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio de Janeiro em GWh.	113
Tabela 9.25 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Paraná em GWh.	114
Tabela 9.26 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Santa Catarina em GWh.	115
Tabela 9.27 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio Grande do Sul em GWh.	115
Tabela 9.28 – Previsão do consumo de energia elétrica do setor industrial Brasileiro utilizando a abordagem híbrida com o método preditivo de suavização exponencial para 24 meses (GWh).	116
Tabela 9.29 – Previsão do consumo de energia elétrica do setor industrial Brasileiro utilizando a abordagem híbrida com o método preditivo de Box e Jenkins para 24 meses (GWh).	117
Tabela 9.30 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Norte e seus estados utilizando o método de suavização exponencial.	118

Tabela 9.31 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Norte e seus estados utilizando o método de Box e Jenkins.	120
Tabela 9.32 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados utilizando o método de suavização exponencial.	122
Tabela 9.33 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados utilizando o método de Box e Jenkins.	123
Tabela 9.34 – Tabela das métricas MAPE e RMSE para os dados da Região Centro-Oeste e seus estados utilizando o método de suavização exponencial.	125
Tabela 9.35 – Tabela das métricas MAPE e RMSE para os dados da Região Centro-Oeste e seus estados utilizando o método de Box e Jenkins.	126
Tabela 9.36 – Tabela das métricas MAPE e RMSE para os dados da Região Sudeste e seus estados utilizando o método de suavização exponencial.	128
Tabela 9.37 – Tabela das métricas MAPE e RMSE para os dados da Região Sudeste e seus estados utilizando o método de Box e Jenkins.	129
Tabela 9.38 – Tabela das métricas MAPE e RMSE para os dados da Região Sul e seus estados utilizando o método de suavização exponencial.	130
Tabela 9.39 – Tabela das métricas MAPE e RMSE para os dados da Região Sul e seus estados utilizando o método Box e Jenkins.	131

Lista de Abreviações e Siglas

ACF	<i>Autocorrelation Function</i> (Função de Autocorrelação)
AIC	<i>Akaike's Information Criterion</i> (Critério de informação de Akaike)
AIC_C	<i>Corrected Akaike's Information Criterion</i> (Critério de informação de Akaike Corrigido)
Corr	Correlação
CV	Coefficiente de Variação
EPE	Empresa de Pesquisa Energética
ETS	<i>Error, Trend, Seasonal</i> (Erro, Tendência e Sazonalidade)
KPSS	Test Kwiatkowski-Phillips-Schmidt-Shin
MAPE	<i>Mean Absolute Percentage Error</i> (Média Percentual Absoluta do Erro)
PACF	<i>Partial Autocorrelation Function</i> (Função de Autocorrelação Parcial)
RMSE	<i>Root Mean Squared Error</i> (Raiz Quadrada do Erro Médio)
SES	<i>Simple Exponential Smoothing</i> (Suavização Exponencial Simples)

Lista de Símbolos

∇^n Operador de n -diferenças em séries temporais.

O consumo de energia elétrica do setor industrial brasileiro vem sendo estudado ao longo dos últimos anos, devido principalmente a sua importância econômica, ambiental e social, além de ser um dos principais indicadores de desenvolvimento de um país. Dessa forma, a análise e projeções do consumo de energia elétrica são informações de grande relevância para o planejamento do sistema energético e, também, para o desenvolvimento do setor industrial.

No Brasil, os dados de consumo de energia elétrica do setor industrial pode ser organizado em uma estrutura hierárquica, considerando a hierarquia definida para o Brasil como o nível superior, para as regiões geográficas (Norte, Nordeste, Centro-Oeste, Sudeste e Sul) sendo o nível intermediário e os estados da federação no nível inferior. Essa estrutura tem como característica fundamental o agrupamento de séries temporais de níveis mais baixos para formar séries em outro nível da hierarquia.

Uma maneira de se realizar análises e previsões em séries temporais hierárquicas é definindo o tipo de abordagem que será implementada. Na abordagem *bottom-up* são realizadas as previsões para as séries temporais que ocupam o nível mais baixo da hierarquia e agregando-as para formar previsões nos níveis superiores. Essa abordagem requer um detalhamento muito grande nos níveis da hierarquia, mas é uma condição para que poucas informações sejam perdidas devido à agregação. Por outro lado, a abordagem *top-down* gera as previsões na série completamente agregada e, em algumas situações, desagrega tais previsões para os níveis exigidos, baseada em proporções históricas.

Neste trabalho, serão comparadas as abordagens *bottom-up*, *top-down*, o método de combinação ótima e uma abordagem híbrida para previsão do consumo de energia elétrica do setor industrial brasileiro. Além disso, esse trabalho propõe uma metodologia para abordagem híbrida entre as abordagens *bottom-up* e *top-down*. Os modelos de séries temporais de Box e Jenkins, e de suavização exponencial foram incorporados as abordagens utilizadas neste trabalho. Estes modelos preditivos são utilizados por terem a capacidade de capturar as componentes de tendência, mudança de nível e sazonalidade das séries temporais de consumo de energia elétrica do setor industrial.

1.1 Motivação

A maior parte do abastecimento de energia elétrica no Brasil vem de usinas hidrelétricas, cerca de 53,4% (EPE, 2022c). Apesar de caracterizar uma energia renovável é altamente dependente de chuvas. Dessa forma, se torna importante o planejamento energético nacional e, em particular, para o setor industrial.

No Brasil, o setor industrial é o maior consumidor de energia elétrica. O consumo de energia elétrica deste setor pode ser organizado em uma estrutura hierárquica (Figura 1.1). Portanto, as projeções do consumo de energia elétrica podem contribuir com o planejamento energético do Brasil e o desenvolvimento do setor.

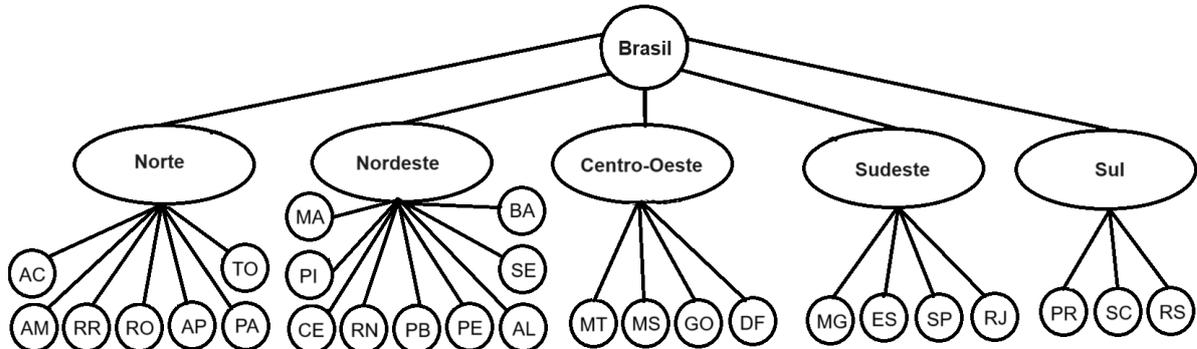


Figura 1.1 – Esquema hierárquico de dois níveis contendo a série nacional, regionais e estados.

Fonte: Autor (2023)

Além disso, há um interesse em investigar as abordagens que possam contribuir com a previsão de séries temporais hierárquicas. Estas abordagens permitem avaliar efeitos de políticas de eficiência energética em cada nível da estrutura hierárquica.

1.2 Objetivo

O objetivo deste trabalho é comparar diferentes abordagens utilizadas para previsão de séries temporais hierárquicas aplicadas ao consumo de energia elétrica do setor industrial. Em particular, foram consideradas as abordagens *bottom-up*, *top-down*, o método de combinação ótima e uma abordagem híbrida proposta neste trabalho. Essas abordagens incorporaram as projeções obtidas pelos métodos preditivos de suavização exponencial e de Box e Jenkins. Como objetivos específicos, pretende-se:

- Organizar os dados estaduais, regionais e nacionais do consumo de energia elétrica do setor industrial brasileiro em uma estrutura hierárquica.
- Avaliar a estrutura hierárquica de dois níveis (Brasil, regiões e estados) considerada neste trabalho.
- Realizar uma análise exploratória para as séries temporais de consumo de energia elétrica afim de encontrar algum comportamento que ajude na implementação de modelos preditivos.
- Implementar as abordagens *top-down*, *bottom-up*, combinação ótima e híbrida incorporadas aos métodos preditivos de suavização exponencial e Box e Jenkins na obtenção de previsões do consumo de energia elétrica do setor industrial brasileiro.
- Avaliar a capacidade preditiva entre as abordagens pelas métricas MAPE e RMSE.

1.3 Organização da Dissertação

No capítulo 2 encontra-se algumas bibliografias relacionadas ao trabalho. Nesta seção, foi realizada uma revisão literária sobre as abordagens em séries temporais hierárquicas e os

métodos preditivos usados neste trabalho. No capítulo 3 tem-se a revisão teórica dos principais temas abordados. O capítulo é separado em seções, a primeira é a seção de séries temporais e depois, nas seções seguintes, modelos de suavização exponencial, modelos de Box e Jenkins, avaliação de modelos preditivos e estudo sobre as séries temporais hierárquicas e suas abordagens. No capítulo 4 encontra-se os materiais e métodos. No capítulo 5 será apresentado a análise exploratória de dados de todas as séries temporais utilizadas neste trabalho. No capítulo 6 estão os principais resultados de cada modelagem e as comparações entre as abordagens. Por fim, no capítulo 7, 8 e 9 estão as conclusões, anexos e referências bibliográficas, respectivamente.

Revisão Bibliográfica

Neste capítulo, será apresentada uma revisão de trabalhos relacionados com séries temporais hierárquicas e suas principais abordagens.

As principais abordagens utilizadas na literatura para previsão de séries temporais hierárquicas são os métodos *top-down* e *bottom-up*. Na abordagem *top-down* é realizado análises e previsões na série que se encontra no topo da hierarquia, depois é utilizado proporções para desagregar os dados para construir as séries de base. Existem vários métodos para encontrar essas proporções, contudo o método mais comum é utilizando proporções históricas dos dados (ATHANASOPOULOS et al., 2009). Na abordagem *bottom-up* as previsões são realizadas nas séries na base hierárquica e assim, são agregadas para compor as séries de níveis superiores. Uma vantagem dessa abordagem é que prevendo nos níveis inferiores da hierarquia nenhuma informação é perdida devido a agregação.

Dangerfield e Morris (1992) compararam as abordagens *bottom-up* e *top-down* em estruturas hierárquicas simples, foram utilizadas 15.753 séries hierárquicas e verificou-se que para esses dados a abordagem *bottom-up* apresentou melhor desempenho em aproximadamente 75% dos casos. Schwarzkopf et al. (1988) comparou o desempenho das abordagens *bottom-up* e *top-down* de maneira computacional e analítica. Após as análises, verificaram que o custo computacional foi praticamente igual e provaram analiticamente que não existem evidências que corroboram que uma abordagem é melhor que a outra. Chen e Boylan (2009) investigaram se a correlação entre as duas séries de base, sem a componente de tendência, afeta a qualidade da previsão hierárquica. Os resultados mostraram que a abordagem *bottom-up* mostrou melhores previsões em relação ao *top-down* quando a correlação entre as séries é altamente positiva, contudo, a abordagem *top-down* é melhor quando a correlação é altamente negativa.

A abordagem de combinação ótima foi introduzida por Hyndman et al. (2011). Esta abordagem combina de maneira ideal as previsões de base para produzir um conjunto de previsões mais próximas possíveis das previsões univariadas. Em Athanasopoulos et al. (2009) encontra-se um estudo sobre o turismo doméstico australiano, onde apresentam análises para dois tipos de hierarquias. Foi utilizado o método de suavização exponencial e cinco abordagens em séries temporais hierárquicas, dentre elas, o método de combinação ótima, este, obtendo resultados satisfatórios. Hyndman et al. (2016) apresentaram a abordagem de mínimos quadrados para reconciliar previsões de séries temporais hierárquicas. Wickramasuriya e Hyndman (2019) utilizaram o método de combinação ótima, incorporando informações de uma matriz de covariância através de erros de previsão. Wickramasuriya et al. (2020) desenvolveram uma metodologia para reconciliação de séries temporais hierárquicas para fornecer previsões não negativas. Spiliotis et al. (2021) propõem uma abordagem de previsão hierárquica baseada em

aprendizado de máquina. Essa abordagem permite combinações não lineares das previsões de base, sendo assim mais geral do que as abordagens lineares. Wang et al. (2022) forneceram uma revisão extensa sobre diferentes métodos de previsão de séries temporais hierárquicas nos últimos 50 anos.

Na análise de sistemas de energia, a abordagem *bottom-up* vem sendo introduzida desde 1980 (CHATEAU; LAPILLONNE, 1978). Ghedamsi et al. (2016) previu até 2040 o consumo de energia elétrica residencial na Argélia utilizando *bottom-up* e obteve resultados satisfatórios. Herbst et al. (2012) avaliaram a demanda e o fornecimento de energia futura utilizando modelos de energia *bottom-up* e *top-down*. Neste estudo salientaram que um modelo energético *bottom-up* possui maior detalhamento dos dados quando comparado a um modelo *top-down*. Fleiter et al. (2012) adotaram uma abordagem *bottom-up* determinística para analisar e prever o consumo de energia elétrica a longo prazo de indústria de papel e celulose na Alemanha. Huang et al. (2016) projetaram o consumo de energia elétrica a longo prazo da indústria de cimento em Taiwan através de uma abordagem *bottom-up*. Yi et al. (2016) analisaram a rede elétrica inter-regional na China até 2030 utilizando abordagens *bottom-up*. Lee e Huh (2017) implementaram uma abordagem *bottom-up* para o planejamento de fornecimento de energia renovável na Coreia do Sul. Taieb et al. (2020) apresentaram um método de previsões probabilísticas hierárquicas para os dados de fornecimento de eletricidade em uma rede elétrica na Inglaterra.

No Brasil, recentemente Maçaira et al. (2015) compararam modelos de suavização exponencial para o consumo de energia elétrica do setor residencial brasileiro. Silva et al. (2018) introduziram uma abordagem *bottom-up* para obter a previsão de longo prazo do consumo de energia elétrica da indústria de papel e celulose. Silva et al. (2019) propõem um modelo que combina os modelos lineares hierárquicos com abordagem *bottom-up*, aplicado ao consumo de energia elétrica da indústria de papel e celulose. Maçaira et al. (2020) avaliaram o efeito de medidas de eficiência energética no setor residencial através de uma abordagem *bottom-up*. Silva et al. (2022) apresentaram um estudo comparativo usando os modelos de redes neurais artificiais para previsão do consumo de eletricidade do setor industrial brasileiro. Meira et al. (2023) apresentaram uma abordagem de reconciliação de previsão hierárquica com o intuito de fornecer previsões precisas de demanda de energia em todos os níveis de um sistema de energia.

A EPE (Empresa de Pesquisa Energética) é responsável pelo planejamento energético no Brasil e vem desenvolvendo a previsão de demanda de energia elétrica de médio e longo prazo através das abordagens *bottom-up* e *top-down* (EPE, 2022b).

Nesta seção, foi apresentada uma revisão da literatura de séries temporais hierárquicas contendo diferentes metodologias. Assim, verificou-se que a abordagem híbrida proposta neste trabalho não foi apresentada em nenhuma pesquisa.

Revisão Teórica

Neste capítulo, será apresentada a parte teórica envolvendo as abordagens utilizadas para previsão hierárquica e os métodos preditivos de suavização exponencial e de Box e Jenkins.

3.1 Séries Temporais

Uma série temporal é qualquer conjunto de observações ordenada ao longo do tempo. Essas observações podem ter frequências constantes ou não, além disso, cada observação pode ser em segundos, minutos, diárias, mensais, anuais, etc., podendo variar dependendo do fenômeno a ser estudado.

O interesse em estudar séries temporais é na modelagem de problemas que envolvem observações sequenciais. Essa modelagem, em geral, tem o objetivo de prever valores futuros, descrever o comportamento da série e investigar o mecanismo da sua geração (MORETTIN P. A.; TOLOI, 2018).

3.1.1 Tendência e Sazonalidade

Suponha uma série temporal em que suas observações podem ser rotuladas por $\{y_t, t = 1, 2, \dots, n\}$, pode-se decompô-la por três componentes, expostas pela equação abaixo:

$$y_t = b_t + s_t + a_t \quad (3.1)$$

Em que, b_t é a componente de tendência, s_t é a componente de sazonalidade e a_t é a componente de ruído ou aleatória, de média zero e variância σ^2 . A componente de tendência é o aumento ou diminuição gradual das observações ao longo do período. A tendência não é obrigatoriamente linear, existem casos, por exemplo, de crescimento ou decrescimento exponencial ou quadrático. A sazonalidade são flutuações na série temporal causada por fatores sazonais, como a época do ano ou dia da semana. São ciclos de frequência fixa e conhecida.

3.1.2 Estacionalidade e Diferenciação

Uma série temporal é dita estritamente estacionária se a distribuição de probabilidade conjunta de y_{t_1}, \dots, y_{t_n} é a mesma que $y_{t_1+\tau}, \dots, y_{t_n+\tau}$. Ou seja, o deslocamento da origem dos tempos por uma quantidade τ não tem efeito na distribuição conjunta que portanto depende apenas dos intervalos entre t_1, \dots, t_n .

Isso significa que para toda a distribuição de probabilidade y_t é a mesma para todo t de modo que a média $\mu(t)$ e a variância $Var(t)$ são constantes, isto é,

$$\mu(t) = \mu, \quad Var(t) = \sigma^2 \quad (3.2)$$

Uma série temporal pode ser estacionária durante todo o tempo analisado ou durante frações desse tempo, nesse ultimo caso, a série pode ser estacionária flutuando ao redor de uma média fixa num certo patamar e depois mudar de nível (subindo ou descendo) e flutuar ao redor de outra média e assim por diante, podendo mudar a inclinação ou não.

A maioria das séries temporais não são estacionárias (MORETTIN P. A.; TOLOI, 2018). Dessa forma, estudar a presença de tendência, sazonalidade e estacionariedade em uma série temporal é importante para o previsor inferir algum método preditivo que ira se ajustar aos dados e entregando um controle do erro maior.

Muitos dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias (MORETTIN P. A.; TOLOI, 2018), caso a série não seja, é necessário alguma transformação nos dados. A transformação mais comum é tomar *diferenças* sucessivas na série até obter a estacionariedade. Ademais, geralmente, até duas diferenças sucessivas já encontra-se uma série temporal estacionária.

A primeira diferença de y_t é definida por:

$$\Delta y_t = y_t - y_{t-1} \quad (3.3)$$

a segunda diferença é definida por:

$$\Delta^2 y_t = \Delta[\Delta y_t] = \Delta[y_t - y_{t-1}] \quad (3.4)$$

logo,

$$\Delta^2 y_t = y_t - 2y_{t-1} + y_{t-2} \quad (3.5)$$

Além disso, para a n -ésima diferença, em geral, é:

$$\Delta^n y_t = \Delta[\Delta^{n-1} y_t] \quad (3.6)$$

A diferença sazonal é outra forma de atingir estacionariedade. Uma diferença sazonal é a diferença entre uma observação y_t e a observação anterior com uma determinada distância dado pelo *lag* escolhido. Ela é dada pela equação 3.7:

$$\Delta y_t = y_t - y_{t-m}, \quad (3.7)$$

Em que m é o número de *lag* escolhido. Rotula-se m -lags de diferenças após o valor m escolhido. Neste trabalho, caso seja necessário alguma análise de série temporal que envolva diferença sazonal, será usado $m = 12$, além disso, quando realizado uma diferença dada pela equação 3.3, será chamado de diferença simples.

Neste trabalho, caso seja necessário alguma análise de estacionariedade será usado o *teste de Kwiatkowski-Phillips-Schmidt-Shin* conhecido por *teste de KPSS*. Este teste consiste em testar a hipótese nula, que os dados são estacionários, e a hipótese alternativa, que os dados não são estacionários.

3.1.3 Autocorrelação

Assim como a correlação mede a extensão de uma relação linear entre duas variáveis, a autocorrelação mede a relação linear entre observações defasadas de uma série temporal (HYNDMAN; ATHANASOPOULOS, 2018).

Seja y_t uma observação da série temporal, a autocorrelação r_1 mede a relação entre y_t e y_{t-1} . Chama-se autocorrelação de *lag* 1 ou primeira defasagem. Já r_2 , a autocorrelação de *lag* 2, mede a relação entre y_t e y_{t-2} e assim por diante. O valor da autocorrelação r_k é calculado através da fórmula 3.8:

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (3.8)$$

Em que T é a quantidade de observações da série temporal e \bar{y} é a média dos dados da série.

É possível construir um gráfico das autocorrelações de uma série temporal. O gráfico é formado por barras verticais que indicam o valor da autocorrelação em cada defasagem. Observe a figura 3.1:

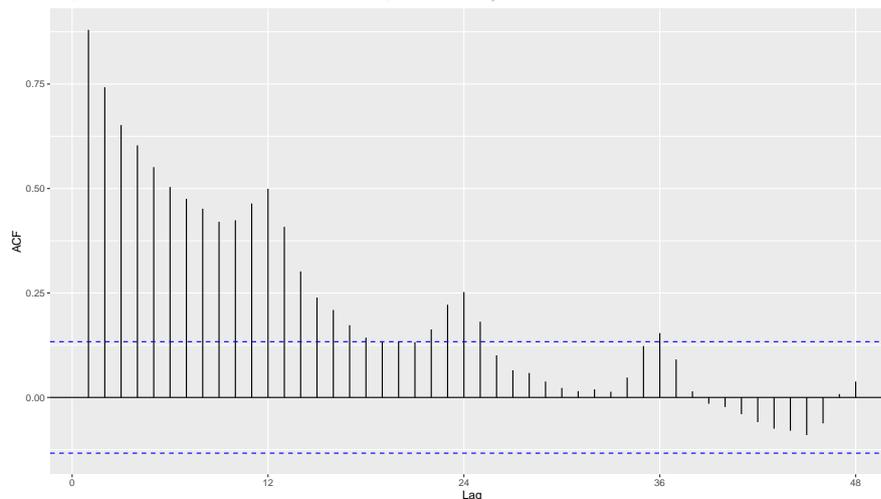


Figura 3.1 – Autocorrelação da série temporal do consumo de energia elétrica do setor industrial brasileiro.

Séries temporais que não apresentam autocorrelações significativas são chamadas de **ruído branco**.

Por outro lado, a função de **autocorrelação parcial** verifica a relação entre duas observações depois de removidas os lags intermediários, ou seja, mede a relação entre y_t e y_{t+k} depois de remover os efeitos das defasagens $1, 2, 3, \dots, k-1$. Por exemplo, o consumo de energia elétrica do setor industrial brasileiro pode ser influenciado pelo consumo do mês passado (y_{t-1}) e do mês retrasado (y_{t-2}), a autocorrelação parcial calcula a autocorrelação desse mês (y_t) com o mês passado sem a influência do mês retrasado. As autocorrelações parciais podem ser obtidas pelo método de Yuller-Walker (MORETTIN P. A.; TOLOI, 2018).

3.1.4 Capacidade Preditiva dos Modelos de Séries Temporais

O resíduo em um modelo de série temporal é a diferença entre o valor observado e o valor ajustado correspondente. Observe a equação 3.9:

$$e_t = y_t - \hat{y}_t \quad (3.9)$$

Existem duas propriedades que devem ser analisadas nos resíduos, a primeira é que os resíduos devem ser não correlacionados e a segunda é que a média dos resíduos deve ser igual a zero.

O erro de previsão é a diferença entre o valor observado e o valor previsto correspondente. O que diferencia o erro de previsão do resíduo é que o resíduo surge do conjunto de treinamento, ou seja, é um erro de ajuste, já o erro de previsão é a diferença do valor que está contido no conjunto de teste e o valor previsto correspondente. Veja a equação 3.10:

$$e_{T+h} = y_{T+h} - \hat{y}_{T+h|T} \quad (3.10)$$

Em que os dados de treinamento são dados por $\{y_1, \dots, y_T\}$ e os dados de teste são dados por $\{y_{T+1}, y_{T+2}, \dots\}$.

Depois de verificar que o modelo atende as exigências impostas aos resíduos, o próximo passo é verificar se o método é capaz de prever bem, e isso é avaliado usando métricas que estudam o erro de previsão. As métricas utilizadas nesse trabalho foram a RMSE (*Root Mean Squared Error*) que significa raiz do erro quadrático médio e o MAPE (*Mean Absolute Percentage Error*) que significa erro percentual médio absoluto. O RMSE é calculado usando a fórmula 3.11:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (3.11)$$

Onde N é a quantidade de dados de erros e $y_t - \hat{y}_t$ representa o erro em cada tempo t . Já o MAPE é calculado utilizando a fórmula 3.12:

$$MAPE = 100 \cdot \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \% \quad (3.12)$$

Onde N é a quantidade de dados de erros e $y_t - \hat{y}_t$ representa o erro em cada tempo t .

Cada métrica possui ressalvas. O RMSE é sensível a escalas dos dados, ou seja, ao comparar dados de energia elétrica de um estado de baixo consumo com outro estado de alto consumo, pode ocorrer que a métrica do estado que consome menos ser bem pequena e isso não é necessariamente que o modelo previu melhor nele do que em outro, contudo, ao comparar abordagens em séries temporais aplicadas na mesma hierarquia a métrica RMSE é a mais indicada. (KOLASSA; HYNDMAN, 2023).

O MAPE é mais interessante quando compara-se previsões entre duas séries temporais pelo fato de não conter unidade, contudo, prever observações próximas de zero pode ocorrer instabilidade no cálculo, levando a resultados confusos.

3.2 Modelos de Suavização Exponencial

Nesta seção serão discutidos os modelos de previsão utilizados neste trabalho, que são os métodos de suavização exponencial e de Box e Jenkins.

3.2.1 Método de Suavização Exponencial

A suavização exponencial foi proposta por [Brown \(1960\)](#); [Holt \(1957\)](#) e [Winters \(1960\)](#). As previsões produzidas usando métodos de suavização exponencial são realizadas através de médias ponderadas de observações anteriores, com os pesos decaindo exponencialmente a medida que as observações envelhecem. Esses pesos são governados por uma constante $\alpha \in [0, 1]$. Quando α está próximo de zero mais peso é dado às observações do passado distante, em contrapartida, se α está próximo de um, mais peso é dado às observações mais recentes.

Existem muitos modelos de suavização exponencial, estes variam de acordo com as características das séries temporais. Como visto anteriormente, uma série pode conter tendência e sazonalidade, contudo, para esses dois componentes, existem duas classificações a serem consideradas, se são aditivas ou multiplicativas.

Uma série que possui dados que mudam gradualmente de nível de maneira quadrática ou exponencial, classifica-se como uma tendência multiplicativa, caso a mudança gradual tenha uma tendência linear, então classifica-se como tendência aditiva ([Figura 3.2](#)). A sazonalidade aditiva ocorre quando as variações sazonais são aproximadamente constantes ao longo da série como na [figura 3.2 \(a\)](#), já o método multiplicativo é utilizado quando as variações sazonais estão mudando proporcionalmente ao nível da série, como na [figura 3.2 \(b\)](#).

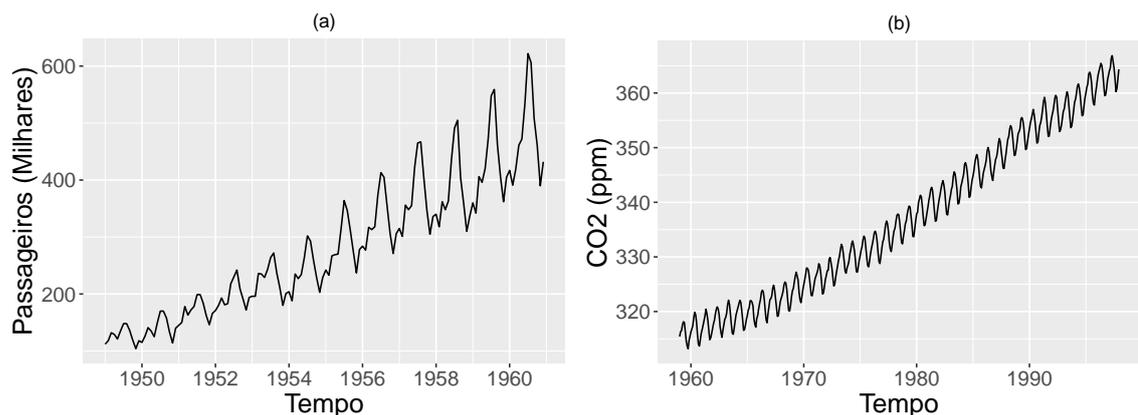


Figura 3.2 – (a) Série temporal mensal que registra o total de passageiros internacionais (em milhares) da linha aérea (Pan Am) no período de janeiro de 1949 à dezembro 1960, nos EUA. (b) Este conjunto de dados contém observações sobre a concentração de dióxido de carbono (CO_2) na atmosfera feitas em Mauna Loa de Janeiro de 1959 à Dezembro de 1998.

3.2.2 Modelos de Suavização Exponencial Simples

O modelo mais simples de suavização exponencial é chamado de **suavização exponencial simples**, também conhecido pela sigla inglesa SES (*simple exponential smoothing*). Este método é geralmente aplicado para séries temporais sem tendência clara ou padrão sazonal aparente.

Para uma série com T observações, a previsão $T + 1$ é igual uma média ponderada entre a previsão mais recente y_T e a previsão anterior $\hat{y}_{T|T-1}$, veja a equação [3.13](#):

$$\hat{y}_{T+1|t} = \alpha y_T + (1 - \alpha) \hat{y}_{T|T-1}, \quad 0 \leq \alpha \leq 1 \quad (3.13)$$

Onde α é o parâmetro de suavização. Observando a forma recursiva do método tem-se:

$$\begin{aligned}
\hat{y}_{2|1} &= \alpha y_1 + (1 - \alpha) \ell_0 \\
\hat{y}_{3|2} &= \alpha y_2 + (1 - \alpha) \hat{y}_{2|1} \\
\hat{y}_{4|3} &= \alpha y_3 + (1 - \alpha) \hat{y}_{3|2} \\
&\vdots \\
\hat{y}_{T|T-1} &= \alpha y_{T-1} + (1 - \alpha) \hat{y}_{T-1|T-2} \\
\hat{y}_{T+1|T} &= \alpha y_T + (1 - \alpha) \hat{y}_{T|T-1}.
\end{aligned}$$

Veja que para a iniciar a recursividade, α e ℓ_0 devem ser estimados. Substituindo recursivamente as equações de previsão, tem-se:

$$\begin{aligned}
\hat{y}_{3|2} &= \alpha y_2 + (1 - \alpha) [\alpha y_1 + (1 - \alpha) \ell_0] \\
&= \alpha y_2 + \alpha(1 - \alpha) y_1 + (1 - \alpha)^2 \ell_0 \\
\hat{y}_{4|3} &= \alpha y_3 + (1 - \alpha) [\alpha y_2 + \alpha(1 - \alpha) y_1 + (1 - \alpha)^2 \ell_0] \\
&= \alpha y_3 + \alpha(1 - \alpha) y_2 + \alpha(1 - \alpha)^2 y_1 + (1 - \alpha)^3 \ell_0 \\
&\vdots \\
\hat{y}_{T+1|T} &= \sum_{j=0}^{T-1} \alpha(1 - \alpha)^j y_{T-j} + (1 - \alpha)^T \ell_0.
\end{aligned} \tag{3.14}$$

A equação 3.14 prevê valores utilizando o método de suavização exponencial simples, contudo, para valores de T grandes, $(1 - \alpha)^T$ torna-se muito pequeno, com isso, o método pode ser aproximado pelo somatório, logo, veja a equação 3.15 contendo o modelo SES simplificado:

$$\hat{y}_{T+1|T} = \alpha y_T + \alpha(1 - \alpha) y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \tag{3.15}$$

Uma outra forma de escrever o modelo SES, é desmembrando a equação 3.13 em duas equações, uma de previsão e outra de suavização. A intenção de escrever dessa forma é somente didática, já que nas próximas subseções serão considerados outras componentes. Observe a equação 3.16:

$$\text{Equação de Previsão} \qquad \hat{y}_{t+h|t} = \ell_t \tag{3.16}$$

$$\text{Equação de Suavização} \qquad \ell_t = \alpha y_t + (1 - \alpha) \ell_{t-1}, \tag{3.17}$$

Onde ℓ_t é chamada de componente de nível ou valor suavizado no tempo t . Repare que ao substituir ℓ_t por $\hat{y}_{t+1|t}$ e ℓ_{t-1} por $\hat{y}_{t|t-1}$ na equação de suavização, recupera-se a equação em forma de média ponderada.

3.2.3 Modelos Holt-Winters com Tendência

Holt (1957) agregou a componente de tendência no método de suavização exponencial simples. Observe a equação:

Equação de Previsão	$\hat{y}_{t+h t} = \ell_t + hb_t$
Equação de Nível	$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1})$
Equação de Tendência	$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}$,

Onde ℓ_t representa a estimativa no nível t , b_t a estimativa de tendência no tempo t , α é o parâmetro de suavização, $0 \leq \alpha \leq 1$, e β^* é o parâmetro de suavização para a tendência, $0 \leq \beta^* \leq 1$.

Observe que a equação de tendência, de nível e de previsão são médias ponderadas. Ademais, as função de previsão contém um termo de tendência, dado por hb_t , onde h multiplica a estimativa de tendência.

3.2.4 Modelos Holt-Winters Sazonal Aditivo

A equação de previsão do método Holt-Winters sazonal aditivo pode ser expresso pela equação 3.18:

$$\hat{y}_{t+h|t} = \ell_t + s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.18)$$

onde h é o horizonte de previsão e p é o período sazonal.

A componente de nível ℓ_t é dada pela equação 3.19:

$$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1}), \quad 0 < \alpha < 1 \quad (3.19)$$

A componente de sazonalidade é dada pela equação 3.20:

$$s_t = \gamma(y_t - \ell_{t-1}) + (1 - \gamma)s_{t-m}, \quad 0 < \gamma < 1 \quad (3.20)$$

Onde α e γ são constantes de suavização das componentes de nível e sazonalidade, respectivamente.

3.2.5 Modelos Holt-Winters com Tendência e Sazonalidade Aditiva

A equação de previsão do método Holt-Winters com tendência e sazonalidade aditiva pode ser expresso pela equação 3.21:

$$\hat{y}_{t+h|t} = \ell_t + hb_t + s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.21)$$

onde h é o horizonte de previsão e p é o período sazonal.

A componente de nível ℓ_t é dada pela equação 3.22:

$$\ell_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}), \quad 0 < \alpha < 1 \quad (3.22)$$

A componente de tendência é dada pela equação 3.23:

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}, \quad 0 < \beta^* < 1 \quad (3.23)$$

A componente de sazonalidade é dada pela equação 3.24:

$$s_t = \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}, \quad 0 < \gamma < 1 \quad (3.24)$$

Onde α , β e γ são constantes de suavização das componentes de nível, tendência e sazonalidade, respectivamente.

3.2.6 Modelos Holt-Winters Sazonal Multiplicativo

A equação de previsão do modelo Holt-Winters Sazonal Multiplicativo pode ser expresso pela equação 3.25.

$$\hat{y}_{t+h|t} = (\ell_t + hb_t)s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.25)$$

onde h é o horizonte de previsão e p é o período sazonal.

A componente de nível é dada pela equação 3.26:

$$\ell_t = \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(\ell_{t-1}), \quad 0 < \alpha < 1 \quad (3.26)$$

A componente de sazonalidade é dada pela equação 3.27:

$$s_t = \gamma \frac{y_t}{\ell_{t-1}} + (1 - \gamma)s_{t-m}, \quad 0 < \gamma < 1 \quad (3.27)$$

Onde α e γ são constantes de suavização das componentes de nível e sazonalidade, respectivamente.

3.2.7 Modelos Holt-Winters com Tendência Aditiva e Sazonalidade Multiplicativa

O modelo Holt-Winters multiplicativo possui algumas mudanças em comparação com o aditivo. Observe a equação 3.28 que governa o modelo.

$$\hat{y}_{t+h|t} = (\ell_t + hb_t)s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.28)$$

onde h é o horizonte de previsão e s é o período sazonal.

A componente de nível é dada pela equação 3.29:

$$\ell_t = \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(\ell_{t-1} + b_{t-1}), \quad 0 < \alpha < 1 \quad (3.29)$$

A componente de tendência é dada pela equação 3.30:

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1}, \quad 0 < \beta^* < 1 \quad (3.30)$$

A componente de sazonalidade é dada pela equação 3.31:

$$s_t = \gamma \frac{y_t}{(\ell_{t-1} + b_{t-1})} + (1 - \gamma)s_{t-m}, \quad 0 < \gamma < 1 \quad (3.31)$$

Onde α , β e γ são constantes de suavização das componentes de nível, tendência e sazonalidade, respectivamente.

3.2.8 Modelos Holt-Winters Amortecido

Evidências empíricas indicam que métodos de tendência constante podem superestimar, principalmente para horizontes de previsão mais longos (HYNDMAN; ATHANASOPOULOS, 2018). Gardner e McKenzie (1985) introduziram um parâmetro ϕ que “amortece” a tendência para as previsões utilizando amortecimento exponencial, onde $0 < \phi < 1$. Veja a equação:

$$\begin{array}{ll} \text{Equação de Previsão} & \hat{y}_{t+h|t} = \ell_t + (\phi + \phi^2 + \dots + \phi^h)b_t \\ \text{Equação de Nível} & \ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}) \\ \text{Equação de Tendência} & b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}. \end{array}$$

Se $\phi = 1$ o método equivale ao método de tendência de Holt. Em geral, ϕ não é inferior a 0,8. É comum o parâmetro está entre 0,8 à 0,98.

3.2.9 Modelos Holt-Winters Amortecido com Sazonalidade Aditiva

A previsão dos valores futuros da série no método de Holt-Winters amortecido aditivo é dado pela equação 3.32:

$$\hat{y}_{t+h|t} = \ell_t + \phi_h b_t + s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.32)$$

onde h é o horizonte de previsão, p é uma estação completa de sazonalidade, ϕ é a taxa de crescimento local e $\phi_h = \phi + \phi^2 + \dots + \phi^h$.

A componente de nível é dada pela equação 3.33

$$\ell_t = \alpha (y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}), \quad 0 < \alpha < 1 \quad (3.33)$$

A componente de tendência é dada pela equação 3.34:

$$b_t = \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1}, \quad 0 < \beta^* < 1 \quad (3.34)$$

A componente de sazonalidade é dada pela equação 3.35:

$$s_t = \gamma(y_t - \ell_{t-1} - \phi b_{t-1}) + (1 - \gamma)s_{t-m}, \quad 0 < \gamma < 1. \quad (3.35)$$

Onde α , β e γ são constantes de suavização das componentes de nível, tendência e sazonalidade, respectivamente.

3.2.10 Modelo Holt-Winters Amortecido com Sazonalidade Multiplicativa

A previsão dos valores futuros da série no método de Holt-Winters amortecido multiplicativo é dado pela equação 3.36:

$$\hat{y}_{t+h|t} = (\ell_t + \phi_h b_t)s_{t+h-m(k+1)}, \quad h = 1, 2, \dots, p \quad (3.36)$$

onde h é o horizonte de previsão, p é uma estação completa de sazonalidade, ϕ é a taxa de crescimento local e $\phi_h = \phi + \phi^2 + \dots + \phi^h$.

A componente de nível é dada pela equação 3.37

$$\ell_t = \alpha \left(\frac{y_t}{s_{t-m}} \right) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}), \quad 0 < \alpha < 1 \quad (3.37)$$

A componente de tendência é dada pela equação 3.38:

$$b_t = \beta^* (\ell_t - \ell_{t-1}) + (1 - \beta^*) \phi b_{t-1}, \quad 0 < \beta^* < 1 \quad (3.38)$$

A componente de sazonalidade é dada pela equação 3.39:

$$s_t = \gamma \frac{y_t}{\ell_{t-1} + \phi b_{t-1}} + (1 - \gamma) s_{t-m}, \quad 0 < \gamma < 1. \quad (3.39)$$

Onde α , β e γ são constantes de suavização das componentes de nível, tendência e sazonalidade, respectivamente.

Todos os métodos de suavização exponencial requer, inicialmente, valores para os parâmetros de suavização. Em alguns casos, os parâmetros são escolhidos de maneira subjetiva, o analista escolhe um valor de acordo com a sua experiência. Contudo, existem maneiras mais confiáveis e objetivas, uma delas é minimizar a soma dos resíduos quadráticos de previsão, isto é, obter o valor do vetor (α, β, γ) que torne a soma dos erros quadráticos de previsão mínima. Em geral, este problema envolve otimização não linear. Para maiores detalhes no cálculo desses parâmetros, consultar (GRANGER C. W. J.; NEWBOLD, 1977).

3.2.11 Classificação Bidirecional de Modelos Holt-Winters

Observando as seções anteriores, é perceptível que existem algumas variações dos métodos de suavização exponencial a ser considerados. Pegels (1969) apud. Hyndman e Athanasopoulos (2018), propôs um método de classificação bidirecional que também considerava tendência multiplicativa, contudo, neste trabalho não será considerado a tendência multiplicativa como possibilidade de modelagem. Hyndman e Athanasopoulos criaram uma classificação bidirecional baseada nas classificações de Pegels, retirando a tendência multiplicativa. Cada método é rotulado por duas letras onde a primeira representa a característica de tendência e a segunda a componente de sazonalidade.

A tendência pode conter três classificações, quando a tendência é aditiva rotula-se como A, quando a tendência é aditiva com amortecimento (*damped*) é rotula-se como A_d , caso não seja considerada, rotula-se como N. A componente de sazonalidade, também, contém três classificações, quando a mesma é aditiva rotula-se como A, caso seja multiplicativa, M, já no caso que a mesma não é considerada, N. Veja a tabela 3.1 com as nove variações:

Tabela 3.1 – Tabela contendo a classificação bidirecional dos modelos de suavização exponencial.

Componente de Tendência	Componente de Sazonalidade		
	N	A	M
	Nenhum	Aditiva	Multiplicativa
N (Nenhum)	(N,N)	(N,A)	(N,M)
A (Aditiva)	(A,N)	(A,A)	(A,M)
A_d (Ad. com <i>damped</i>)	(A_d ,N)	(A_d ,A)	(A_d ,M)

A critério de curiosidade, os métodos supracitados nas seções anteriores podem ser rotulados utilizando as novas classificações bidirecionais. Veja na tabela 3.2:

Nas equações 3.40 contém um resumo das fórmulas de modelos de suavização exponencial associadas a cada classificação bidirecional exposto na tabela 3.1.

Tabela 3.2 – Tabela contendo a associação de métodos de suavização exponencial com a classificação bidirecional (T, S).

Classificação	Método
(N,N)	Suavização exponencial simples
(A,N)	Modelo Holt-Winters com tendência
(N,A)	Modelo Holt-Winters sazonal aditivo
(A,A)	Modelo Holt-Winters com tendência e sazonalidade aditiva
(N,M)	Modelo Holt-Winters sazonal multiplicativo
(A,M)	Modelo Holt-Winters com tendência aditiva e sazonalidade multiplicativa
(A _d ,N)	Modelo Holt-Winters amortecido
(A _d ,A)	Modelo Holt-Winters amortecido com sazonalidade aditiva
(A _d ,M)	Modelo Holt-Winters amortecido com sazonalidade multiplicativa

Modelo Linear de Holt-Winters - (A,N) Suavização Exponencial Simples - (N,N) (3.40)

$$\begin{aligned} \hat{y}_{t+h|t} &= \ell_t + hb_t & \hat{y}_{t+h|t} &= \ell_t \\ \ell_t &= \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1}) & \ell_t &= \alpha y_t + (1 - \alpha)\ell_{t-1} \\ b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1} \end{aligned}$$

Holt-Winters Aditivo Amortecido - (A_d, A) Holt-Winters Multiplicativo Amortecido - (A_d, M)

$$\begin{aligned} \hat{y}_{t+h|t} &= \ell_t + \Phi_h b_t + s_{t+h-m(k+1)} & \hat{y}_{t+h|t} &= [\ell_t + \Phi_h b_t] s_{t+h-m(k+1)} \\ \ell_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}) & \ell_t &= \alpha(y_t / s_{t-m}) + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}) \\ b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1} & b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1} \\ s_t &= \gamma(y_t - \ell_{t-1} - \phi b_{t-1}) + (1 - \gamma)s_{t-m}, & s_t &= \gamma \frac{y_t}{(\ell_{t-1} + \phi b_{t-1})} + (1 - \gamma)s_{t-m} \end{aligned}$$

Holt-Winters Aditivo - (A,A) Holt-Winters Multiplicativo - (A,M)

$$\begin{aligned} \hat{y}_{t+h|t} &= \ell_t + hb_t + s_{t+h-m(k+1)} & \hat{y}_{t+h|t} &= (\ell_t + hb_t) s_{t+h-m(k+1)} \\ \ell_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}) & \ell_t &= \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(\ell_{t-1} + b_{t-1}) \\ b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1} & b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)b_{t-1} \\ s_t &= \gamma(y_t - \ell_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}, & s_t &= \gamma \frac{y_t}{(\ell_{t-1} + b_{t-1})} + (1 - \gamma)s_{t-m} \end{aligned}$$

Holt-Winters Sazonal Aditivo - (N,A) Holt-Winters Sazonal Multiplicativo - (N,M)

$$\begin{aligned} \hat{y}_{t+h|t} &= \ell_t + s_{t+h-m(k+1)} & \hat{y}_{t+h|t} &= (\ell_t) s_{t+h-m(k+1)} \\ \ell_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(\ell_{t-1}) & \ell_t &= \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(\ell_{t-1}) \\ s_t &= \gamma(y_t - \ell_{t-1}) + (1 - \gamma)s_{t-m}, & s_t &= \gamma \frac{y_t}{(\ell_{t-1})} + (1 - \gamma)s_{t-m} \end{aligned}$$

Holt-Winters Amortecido - (A_d,N)

$$\begin{aligned} \hat{y}_{t+h|t} &= \ell_t + \phi_h b_t \\ \ell_t &= \alpha y_t + (1 - \alpha)(\ell_{t-1} + \phi b_{t-1}) \\ b_t &= \beta^*(\ell_t - \ell_{t-1}) + (1 - \beta^*)\phi b_{t-1} \end{aligned}$$

3.3 Modelos de Box e Jenkins

Os modelos de suavização exponencial realizam previsões em séries temporais se baseando em características como tendência, sazonalidade e mudanças de nível, contudo, os modelos de Box e Jenkins utilizam outra abordagem, da autocorrelação dos dados. Estes modelos foram estudados por [Box et al. \(2015\)](#) e busca integrar modelos autorregressivos (AR) e de médias móveis (MA) a um conjunto de observações.

A estratégia para a construção do modelo não é mecânica, e sim, investigativa. O previsor deve analisar os resultados de estimação do modelo e a partir disso testar suas hipóteses utilizando alguma métrica que mede a acurácia do modelo. Veja o ciclo iterativo para propor um modelo de Box e Jenkins:

1. identificar o modelo com base nas funções de autocorrelação;
2. estimação dos parâmetros do modelo;
3. diagnosticar o modelo utilizando o estudo dos resíduos.

Caso o modelo não seja adequado, o ciclo se reinicia. Em algumas ocasiões, as análises das funções de autocorrelação e autocorrelação parcial entregam mais de um modelo, neste caso, escolher-se-á, o método que melhor se ajusta aos dados ou que entrega o menor erro de previsão.

3.3.1 Modelos Autorregressivos (AR)

É importante diferenciar modelos regressivos e autorregressivos, o primeiro busca realizar previsões de uma variável utilizando uma combinação linear de variáveis explanatórias, contudo, o segundo busca realizar previsões utilizando uma combinação linear de observações passadas da própria variável. Veja a equação 3.41 do modelo de autorregressão (AR):

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (3.41)$$

onde ε_t é o ruído branco. Observe que a combinação linear é realizada com valores passados de y_t . Este modelo é rotulado como $AR(p)$, modelo autorregressivo de ordem p .

3.3.2 Modelos de Médias Móveis

O modelo de Médias Móveis utiliza uma regressão dos erros de previsão passados, em vez de observações anteriores como foi descrito nos modelos AR. Veja a equação 3.42:

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (3.42)$$

onde ε_t é o ruído branco. Este modelo é rotulado como $MA(q)$, modelo de médias móveis de ordem q .

3.3.3 Modelos ARIMA

ARIMA é um acrônimo para *AutoRegressive Integrated Moving Average*, ou seja, modelos Autorregressivos Integrados de Médias Móveis. Como o acrônimo indica, o modelo surge

a partir da combinação de modelos autorregressivos e de médias móveis. O modelo completo pode ser escrito como:

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \epsilon_{t-1} + \dots + \theta_p \epsilon_{t-p} + \epsilon_t \quad (3.43)$$

O rótulo y'_t significa a série diferenciada. De maneira geral, o modelo ARIMA é apresentado utilizando três letras na forma ARIMA(p,d,q):

- p é a ordem do modelo Autorregressivo;
- d é a quantidade de diferenciações usadas na série temporal;
- q é a ordem do modelo de médias móveis.

A quantidade de diferenciação deve ser o bastante para tornar a série estacionária. Geralmente, no máximo duas diferenciações é o bastante para tornar um série estacionária, caso a série sob análise já seja estacionária, tem-se $d = 0$. Os valores p e q são extraídos através dos gráficos de autocorrelação e autocorrelação parcial. Na próxima seção encontra-se um exemplo de modelagem para melhor entendimento.

3.3.4 Modelos SARIMA

As séries temporais analisadas neste trabalho possuem alguma sazonalidade, dessa forma, existe a necessidade da utilização de modelos ARIMA que consideram esta característica, logo, as previsões serão feitas utilizando ARIMA Sazonal (SARIMA). O acrônimo SARIMA significa modelos Autorregressivos Integrados de Médias Móveis com Sazonalidade. A estrutura desse modelo de ordem $(p, d, q) \times (P, D, Q)_s$ é dada por

$$\phi(B)\Phi(B^s) \nabla^d \nabla_s^D Y_t = \theta(B)\Theta(B^s) a_t, \quad (3.44)$$

em que $\phi(B)$ é o operador auto-regressivo de ordem p ; $\theta(B)$ é o operador de médias móveis de ordem q ; $\phi(B^s)$ é o operador auto-regressivo sazonal de ordem P ; $\Theta(B^s)$ é o operador de médias móveis sazonal de ordem Q ; ∇^d é o operador da diferença simples; ∇_s^D é o operador da diferença sazonal; a_t é um ruído branco e; s é a quantidade de observações por ano.

Com o intuito didático será exposto a forma que, em geral, o previsor analisa uma série temporal utilizando modelos SARIMA. Considere a série de dados de consumo de energia elétrica do setor industrial brasileiro. O primeiro passo é verificar estacionalidade na série, caso a mesma não tenha, aplicar algum processo de transformação de diferenças. Já que a série não é estacionária, verificado pelo teste de KPSS (p-valor = 0,012), será aplicado uma diferença sazonal. Veja a figura 3.3:

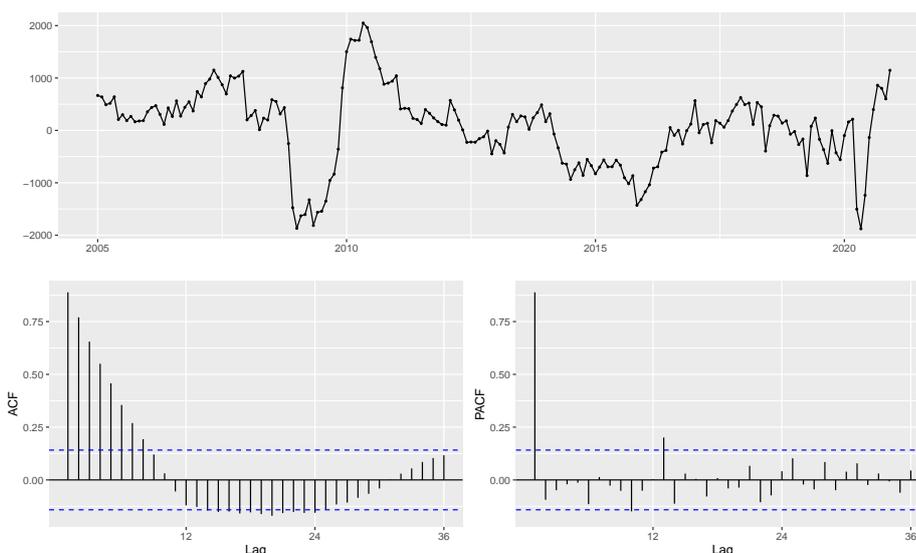


Figura 3.3 – Aplicação de uma diferença sazonal na série dos dados de consumo de energia elétrica do setor industrial brasileiro.

A série continua não estacionária pelo teste KPSS (p-valor = 0.046), com isso, realiza-se um diferença simples. Veja a figura 3.4:

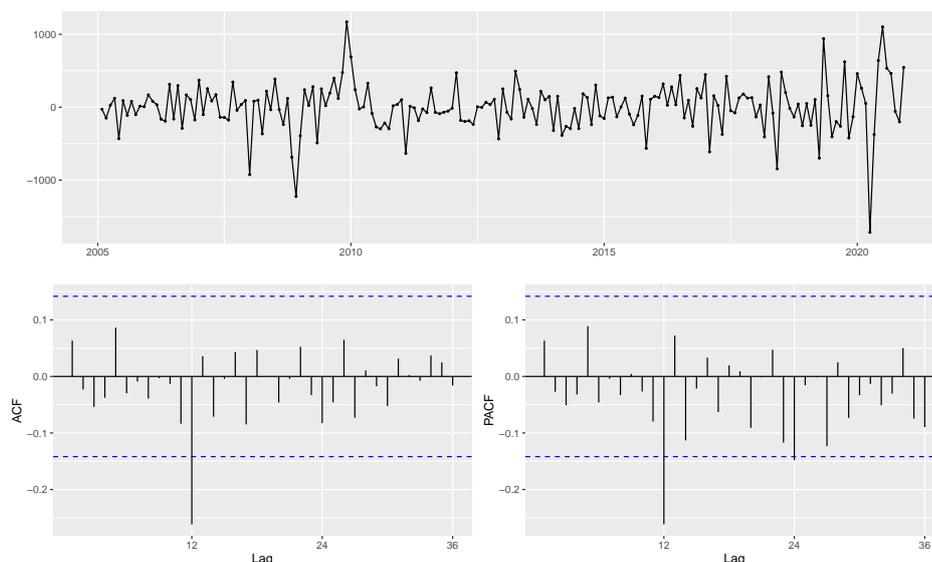


Figura 3.4 – Aplicação de uma dupla diferenciação na série dos dados de consumo de energia elétrica do setor industrial brasileiro.

Agora, a série está estacionária pelo teste de KPSS (p-valor = 0.1). Dessa forma, o modelo SARIMA deve possuir $d = 1$ e $D = 1$, já que d simboliza a quantidade de diferenças simples e D a quantidade de diferença sazonal utilizadas para se obter a estacionariedade. A partir disso, deve-se analisar os gráficos *ACF* e *PACF*, que significa os gráficos de autocorrelação e autocorrelação parcial dos dados diferenciados, na obtenção das constantes p, q, P e Q .

Com o gráfico da autocorrelação (*ACF*) pode-se extrair informações para compor as constantes q e Q que destinam-se para a parte de Médias Móveis. Como existe um lag bem significativo em 12, então segue um componente sazonal em $MA(1)$ ($Q = 1$). Além disso, existe mais um lag significativo em 24, então pode-se considerar outro modelo contendo uma compo-

nente sazonal MA(2) ($Q = 2$). Não existe mais nenhum outro lag significativo não múltiplo de 12, resulta em nenhuma componente MA não sazonal, logo ($q = 0$).

Como o gráfico da autocorrelação parcial pode-se extrair informações para compor as constantes p e P que destinam-se para a parte Autorregressiva. Como existe um lag significativo em 12, então segue um componente sazonal em AR(1) ($P = 1$). Como não existe mais nenhum outro lag significativo não múltiplo de 12, resulta em nenhuma componente AR não sazonal, logo ($p = 0$).

Além disso, existe um algoritmo no *software* R (R Core Team, 2022) conhecido por *auto.arima* que foi construído por Hyndman e Khandakar (2008) que testa modelos de Box e Jenkins a fim de encontrar o modelo que fornece o menor AIC_C (*Corrected Akaike's Information Criterion*). Basicamente, o algoritmo examina a necessidade de diferenças utilizando o teste KPSS e depois testa valores para as constantes p, q, P e Q . Quando selecionado o modelo, o algoritmo também testa modelos com ordem inferiores e superiores (± 1), até o menor AIC_C ser encontrado.

Utilizando o algoritmo o modelo apresentado foi o SARIMA(0, 1, 0)(0, 1, 2)₁₂. Então, tem-se três modelos possíveis: SARIMA(0, 1, 0)(0, 1, 2)₁₂, SARIMA(0, 1, 0)(1, 1, 1)₁₂ e SARIMA(0, 1, 0)(2, 1, 1)₁₂. Contudo, o modelo SARIMA(0, 1, 0)(0, 1, 2)₁₂ possui o menor AIC_C igual a 2735,33, indicando que é o melhor modelo dentre os três.

Agora, é essencial estudar se o modelo apresentou resíduos sem correlação, já que isso simboliza que o modelo utilizou todas as informações necessárias para a fase de ajuste. Veja a figura 3.5:

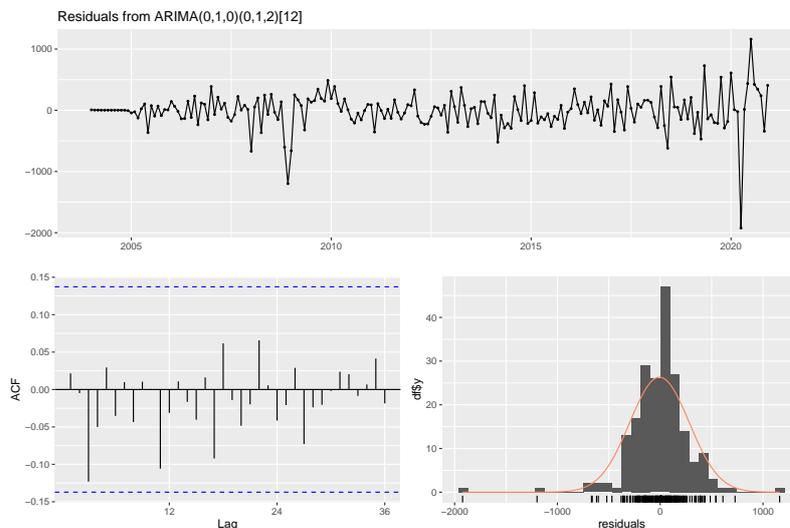


Figura 3.5 – Gráfico contendo a série temporal, a função de autocorrelação dos resíduos e a distribuição dos resíduos para o modelo SARIMA(0, 1, 0)(0, 1, 2)₁₂.

Observe no gráfico *ACF* que todos os lags não exibem correlação significativa, dessa forma, o modelo está ajustado e pode ser usado para realizar previsões. Neste trabalho será recorrido a função *auto.arima* do *software* R para a obtenção de modelos SARIMA para todas as séries temporais.

3.4 Avaliação dos Modelos Preditivos

É importante salientar que a tabela 3.2 e na associação exposta nas equações 3.40 podem entregar a falsa sensação que o processo de modelagem de suavização exponencial é mecânico,

já que este é um processo investigativo, ou seja, mesmo que, por exemplo, uma série temporal possua sazonalidade e tendência, ela pode ser modelada pelo método (N,N), pois o que irá definir o método a ser utilizado é a qualidade das previsões, que nesse sentido, é verificado por métricas que estudam o erro preditivo.

Um das métricas utilizadas para verificar se um determinado modelo se ajusta bem aos dados são as chamadas AIC e AIC_c , que são siglas inglesas para *Akaike's Information Criterion* e *Corrected Akaike's Information Criterion* respectivamente, que significam critério de informação de Akaike e critério de informação de Akaike corrigido. Observe a equação 3.45 contendo a métrica AIC :

$$AIC = T \log \left(\frac{SSE}{T} \right) + 2(k+2) \quad (3.45)$$

Onde, a sigla SSE (*sum of squared errors*) significa a soma quadrática dos erros, T é o número de observações usadas para estimativa e k é o número de parâmetros do modelo. Contudo, para menos de 500 observações na série temporal é realizado um ajuste na métrica AIC , doravante, surge a métrica AIC_c , veja a equação 3.46

$$AIC_c = AIC + \frac{2(k+2)(k+3)}{T-k-3} \quad (3.46)$$

Quanto menor o valor numérico da métrica, melhor o método empregado. Neste trabalho, para investigar o melhor método bidirecional de suavização exponencial e o melhor modelo de Box e Jenkins será utilizado a métrica AIC_c , os resultados serão expostos no capítulo 6 utilizando tabelas que associam a série temporal ao modelo bidirecional.

3.5 Séries Temporais Hierárquicas

As notações trabalhadas nesta dissertação seguem o desenvolvimento de [Hyndman e Athanasopoulos \(2018\)](#).

As séries temporais, em muitas ocasiões, podem ser desagregadas em vários atributos de interesse, formando uma hierarquia. A figura 3.6 representa uma hierarquia com dois níveis, com menos séries do que a hierarquia de consumo energético, o intuito é exibir algumas definições importantes à posteriori.

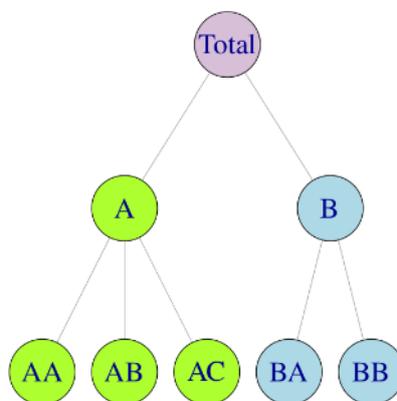


Figura 3.6 – Série temporal hierárquica de dois níveis.

Fonte: Hyndman & Athanasopoulos (2018)

Rotula-se o número total de séries na hierarquia de n e a quantidade máxima de séries na base da hierarquia de m . Neste pequeno exemplo da figura 3.6, o valor de $n = 1 + 2 + 5 = 8$

Seja $\hat{Y}_{X,n}(h)$ a previsão h -passo-à-frente da série X e $\hat{Y}_n(h)$ é um vetor que contém todas as previsões de cada série e de cada nível realizadas de maneira independente, à elas Hyndman et al. (2011) chamam de *previsões de base*. As previsões para a estrutura hierárquica pode ser representada como:

$$\tilde{Y}_h = SG\hat{Y}_n(h) \quad (3.51)$$

O vetor $\tilde{Y}_n(h)$, na equação 3.51, é chamado de previsão revisada. A matriz S tem a tarefa de somar as previsões de base e G é a matriz referente a abordagem implementada.

É importante notar que na equação 3.50, o vetor b_t representa as observações das séries na base da hierarquia, ou seja, a dimensão é numericamente igual a quantidade de séries que ocupam a base da hierarquia, em contrapartida, o vetor $\hat{Y}_n(h)$ representa as previsões de todas as séries da hierarquia de maneira independente em um determinado h -passo-à-frente, então, a dimensão é numericamente igual a quantidade total de séries na hierarquia. As componentes do vetor $\hat{Y}_n(h)$ são organizadas na mesma forma que as séries estão dispostas na hierarquia.

3.6 Abordagens de Previsão Hierárquica

Nesta seção será exposto a metodologia das abordagens em séries temporais hierárquicas utilizadas neste trabalho.

3.6.1 A Abordagem *Bottom-up*

A abordagem *bottom-up* consiste em utilizar modelos preditivos em cada série na base da hierarquia e, em seguida, somá-las para produzir previsões para toda a hierarquia. É uma abordagem muito utilizada em séries temporais hierárquicas, pois capta características importantes como sazonalidade e tendência das séries de base, assim contribuindo para o grau de assertividade da previsão para a série totalmente agregada. Contudo, o analista deve atentar-se que, em alguns casos, as séries de base podem ser muito ruidosas e isso irá prejudicar a previsão. Para avaliar a qualidade dos dados é necessário uma análise exploratória.

Na equação 3.51 é exibido de maneira geral, o método utilizado para prever na metodologia de séries hierárquicas. No tocante a abordagem *bottom-up*, G é dada por uma matriz nula acoplada com uma matriz identidade a direita.

$$G = [0_{m \times (n-m)} | I_m] \quad (3.52)$$

Onde $0_{m \times (n-m)}$ é a matriz nula e I_m é a matriz identidade. Logo, para o problema de consumo de energia elétrica tratado nesse trabalho tem-se:

$$G = [0_{27 \times 6} | I_{27}] \quad (3.53)$$

Note que, no método *bottom-up* a matriz nula contida em G anula as previsões básicas da série acima do nível inferior, enquanto a matriz identidade seleciona apenas as previsões de base e a partir disso, são somados pela matriz S para formar as previsões coerentes \tilde{Y}_h .

3.6.2 A Abordagem *Top-Down*

Na abordagem *top-down*, primeiramente, as previsões são realizadas para a série mais agregada $y_{B,h}$, em seguida, utiliza-se um conjunto de proporções p_1, p_2, \dots, p_m para desagregar

os dados e compor as previsões de nível inferior. Observe:

$$\tilde{y}_{N,h} = p_1 \hat{y}_{B,h}; \quad \tilde{y}_{O,h} = p_2 \hat{y}_{B,h}$$

$$\tilde{y}_{C,h} = p_3 \hat{y}_{B,h}; \quad \tilde{y}_{D,h} = p_4 \hat{y}_{B,h}; \quad \tilde{y}_{S,h} = p_5 \hat{y}_{B,h} \quad (3.54)$$

Nas equações 3.54, os dados de nível Brasil foram desagregados em cada região geográfica. A partir disso, as previsões de cada região serão particionadas para compor as previsões dos estados, novamente, utilizando as proporções.

Usando uma notação matricial, tomando $p = (p_1, \dots, p_{27})^t$, segue:

$$\tilde{b}_h = p \hat{y}_h \quad (3.55)$$

Na literatura, existem muitas formas de encontrar conjuntos de proporções para aplicar a abordagem *top-down*. O cálculo das proporções de médias históricas é obtido através as proporções dados pela fórmula:

$$p_j = \frac{\sum_{t=1}^T \frac{y_{j,t}}{T}}{\sum_{t=1}^T \frac{y_t}{T}} \quad (3.56)$$

Cada proporção p_j , para $j = 1, \dots, m$, captura o valor histórico médio da série de nível inferior $y_{j,t}$ em relação ao valor médio do agregado total y_t . Neste trabalho, como o intuito é realizar previsões na série totalmente agregada, não será necessário a aplicação das proporções, ou seja, somente será utilizado as previsões da série univariada no topo das hierarquias.

Na abordagem *top-down*, as previsões são obtidas para série agregada e, assim, o método não captura o comportamento das séries temporais de base.

3.6.3 A Abordagem de Combinação Ótima

Todas as abordagens vistas até agora podem ser escritas de acordo com a equação matricial 3.51. Além das abordagens citadas existem abordagens híbridas e uma das mais conhecidas é a *middle-out* que combina as abordagens *bottom-up* e *top-down* na qual, dependendo da forma como é aplicada podem gerar tipos de matrizes G distintas. É prudente imaginar a possibilidade de uma matriz G "ótima", ou seja, que teoricamente entrega uma previsão de erro mínimo dentro de um conjunto de previsões coerentes.

A primeira premissa de qualquer método preditivo é a imparcialidade, ou seja, é necessário assumir que as previsões de base (independentes) são imparciais. Para que isso aconteça deve atender a equação 3.57:

$$E[\hat{Y}_n(h)] = E[Y_n(h)] \quad (3.57)$$

Além disso, a previsão revisada também deve ser não viesada. Então:

$$E[\tilde{Y}_n(h)] = E[Y_n(h)] \quad (3.58)$$

Como $Y_n(h) = SY_{K,n}(h)$, tem-se:

$$E[\tilde{Y}_n(h)] = E[SY_{K,n}(h)] = S \cdot E[Y_{K,n}(h)] \quad (3.59)$$

Suponha que $\beta_n(h) = E[Y_{K,n+h} | Y_1, \dots, Y_n]$, que representa a esperança da previsão das séries de base, então tem-se que:

$$E[\tilde{Y}_n(h)] = SG \cdot E[\hat{Y}_n(h)] = SGS \cdot E[Y_{K,h}(h)] \quad (3.60)$$

Então, comparando com a equação 3.59, para que a equação 3.60 nos entregue uma previsão revisada seja não viesada é necessário que:

$$SGS = S \quad (3.61)$$

É evidente que a abordagem *bottom-up* atende o requisito exposto na equação 3.61, com isso, essa abordagem sempre entrega previsões não viesadas. Todavia, o método *top-down* não atende este pré-requisito.

De acordo com Hyndman et al. (2011), pode-se calcular a variância das previsões revisadas. Suponha que a variância das previsões de base $\hat{Y}_n(h)$ é dado por Σ_h , então $Var[\tilde{Y}_n(h)]$ é:

$$Var[\tilde{Y}_n(h)] = SG\Sigma_h G^t S^t \quad (3.62)$$

Dado uma abordagem e uma hierarquia, obtém-se S e G , logo, obtendo Σ_h , calcula-se a variância e os intervalos de previsão revisado. Wickramasuriya e Hyndman (2019) propuseram uma abordagem que reescreve a previsão de base como uma equação de regressão, conhecida como combinação ótima. Veja:

$$\hat{Y}_n(h) = S\beta_n(h) + \epsilon_n \quad (3.63)$$

onde ϵ_n representa o erro da regressão e não deve ser confundido com o erro de previsão. Além disso, ϵ_n tem média zero e variância Σ_h .

Em seu trabalho, Wickramasuriya e Hyndman (2019), utilizou o método dos mínimos quadrados para estimar β_n . Ele encontrou que a equação 3.63 pode ser reescrita como:

$$\tilde{Y}_n(h) = S(S^t S)^{-1} S^t \hat{Y}_n(h) \quad (3.64)$$

Note que a matriz $G = (S^t S)^{-1} S^t$, ou seja, no método de combinação ótima, a matriz G depende exclusivamente da forma da estrutura hierárquica. Isso implica que, a matriz pode ser reutilizada em outros problemas com organização hierárquica igual.

Materiais e Métodos

4.1 Materiais

Neste trabalho, foram utilizados os dados mensais de janeiro de 2004 até dezembro de 2021 do consumo mensal de energia elétrica do setor industrial brasileiro, das suas regiões geográficas e dos estados da federação incluindo o Distrito Federal em *GWh*, disponível no sítio eletrônico da Empresa de Pesquisa Energética (EPE, 2022a).

4.2 Metodologia

As etapas da metodologia utilizada neste trabalho são apresentadas pelo fluxograma da Figura 4.1.

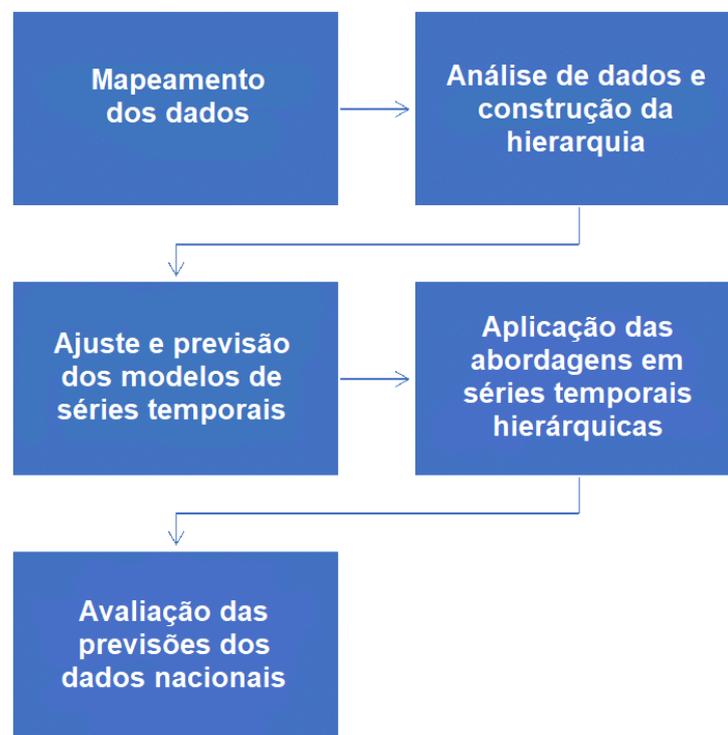


Figura 4.1 – Fluxograma com as etapas da metodologia.

Fonte: Autor (2023)

Neste estudo, foram analisados duas estruturas de séries temporais hierárquicas, a primeira estrutura hierárquica foi composta por seis séries temporais, onde a série de topo (nível superior) são os dados de consumo de energia elétrica do setor industrial brasileiro e as séries de base são as séries de consumo de energia elétrica das cinco regiões geográficas do Brasil: Norte, Nordeste, Centro-Oeste, Sudeste e Sul. Ou seja, os atributos de interesse desta hierarquia são posições geográficas, que estes atributos serão os mesmos para as outras duas análises hierárquicas.

A segunda estrutura hierárquica foi definida com dois níveis, em que a série de topo são os dados de consumo de energia elétrica do setor industrial brasileiro, o nível intermediário são as regiões geográficas e, além disso, em cada região, agrupou-se os dados em cada estado. Os dados da região Norte foram reagrupados em sete grupos (Acre, Amazonas, Roraima, Rondônia, Pará, Amapá e Tocantins); na região Nordeste foi reagrupados em nove grupos (Maranhão, Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia); na região Centro-Oeste tem-se quatro grupos (Mato Grosso, Mato Grosso do Sul, Goiás e Distrito Federal); na região Sudeste, quatro grupos (Minas Gerais, São Paulo, Espírito Santo e Rio de Janeiro); por fim, a região Sul com três grupos (Paraná, Santa Catarina e Rio Grande do Sul) e assim formando a base da hierarquia.

Uma outra análise de estrutura hierárquica, foi realizada para cada região geográfica em que a série totalmente agregada é a série regional e a base é composta pelos seus respectivos estados (Anexo 9).

Para a estrutura hierárquica de dois níveis definida neste trabalho, o consumo de energia elétrica do setor industrial brasileiro foi organizado na seguinte estrutura de séries temporais como descrito na tabela 4.1.

Tabela 4.1 – Quantidade total e por nível de séries temporais na hierarquia.

Nível	Quant. de Séries	Total
Brasil	1	1
Região	5	6
Estados	27	33

Na tabela 4.1 está exposto a quantidade máxima de série na hierarquia é $n = 33$ e na base da hierarquia se encontra $m = 27$ séries temporais. Como a hierarquia é extensa é necessário definir rótulos para cada série. A tabela 4.2 expõe as notações que serão usadas neste trabalho.

De acordo com a equação matricial 3.50, para o problema de consumo de energia elétrica do setor industrial brasileiro, a matriz S é de ordem 33×27 , y_t e b_t possuem ordem 33×1 e 27×1 , respectivamente. A partir dessa estrutura hierárquica, as abordagens *bottom-up*, *top-down*, híbrida e o método de combinação ótima incorporaram as previsões do consumo energia obtidas pelo método de suavização exponencial e pela metodologia de Box e Jenkins.

4.2.1 Etapas de comparação das abordagens

Para avaliar a capacidade preditiva das abordagens dividiu-se as séries temporais hierárquicas em dois conjuntos: o conjunto de treinamento, com o intuito de ajustar e validar os modelos e o conjunto de teste para avaliar a capacidade preditiva. Assim, foi proposto cinco cenários de conjunto de treino e teste. No primeiro cenário, o conjunto de treinamento foram consideradas as observações de janeiro de 2004 até dezembro de 2016 e o conjunto teste, sempre definido para doze observações à frente do conjunto de treinamento, logo, de janeiro de 2017 até dezembro de 2017.

Tabela 4.2 – Notações das séries temporais que compõe a hierarquia.

$Y_{X,t}$	X	$Y_{X,t}$	X	$Y_{X,t}$	X
Brasil	B	Acre	AC	Tocantins	TO
Região Norte	N	Amazonas	AM	Maranhão	MA
Região Nordeste	O	Rondônia	RO	Piauí	PI
Região Centro-Oeste	C	Roraima	RR	Ceará	CE
Região Sudeste	D	Amapá	AP	Rio Grande do Norte	RN
Região Sul	S	Pará	PA	Paraíba	PB
Pernambuco	PE	São Paulo	SP	Paraná	PR
Alagoas	AL	Rio de Janeiro	RJ	Santa Catarina	SC
Sergipe	SE	Mato Grosso	MT	Rio Grande do Sul	RS
Bahia	BA	Mato Grosso do Sul	MS		
Minas Gerais	MG	Goiás	GO		
Espírito Santo	ES	Distrito Federal	DF		

No segundo cenário aumentou-se o conjunto de treinamento com as doze observações do ano de 2017 e o conjunto de teste com os dados de janeiro de 2018 até dezembro de 2018, e assim sucessivamente até no quinto e último cenário. Com isso, foi calculado a média das métricas MAPE e RMSE de cada cenário com o intuito de comparar as abordagens *bottom-up*, *top-down*, híbrida e o método de combinação ótima.

4.2.2 Abordagem híbrida proposta

Existem abordagens em séries temporais hierárquicas que utilizam outras abordagens já consagradas na literatura de forma híbrida, uma abordagem desse tipo é a *middle-out*, primeiramente é escolhido um nível intermediário, que não necessariamente deve ocupar simetricamente o meio da hierarquia, e a partir dele é realizado as previsões para todas as séries da hierarquia. Realiza-se as previsões de todas as séries do nível intermediário e para as séries acima deste nível aplica-se a abordagem *bottom-up* e as séries que se encontram a baixo do nível intermediário aplica-se a abordagem *top-down*, desagregando as previsões do nível intermediário e compondo as séries abaixo.

Este trabalho propõe uma nova abordagem híbrida usufruindo das abordagens *bottom-up* e *top-down*. Suponha uma série temporal hierárquica onde o conjunto de treinamento de cada série comporte T observações. Realiza-se duas previsões um passo-a-frente separadas, uma utilizando a abordagem *bottom-up*, \hat{y}_{T+1}^b e outra, a abordagem *top-down*, \hat{y}_{T+1}^t para a série totalmente agregada.

Assim, considera-se que a distribuição da previsão, \hat{y}_{T+1}^{bt} , obtida pela abordagem híbrida é dada por

$$\hat{y}_{T+1}^{bt} \sim \mathcal{N}(\mu_{T+1}, \sigma_{T+1}^2) \quad (4.1)$$

em que

$$\mu_{T+1} = \frac{\hat{y}_{T+1}^b + \hat{y}_{T+1}^t}{2} \text{ e } \sigma_{T+1}^2 = \left(\frac{|\hat{y}_{T+1}^b - \hat{y}_{T+1}^t|}{2} \right)^2.$$

onde a média da distribuição, μ_{T+1} , é uma média aritmética entre as duas projeções, através de abordagens *bottom-up* e *top-down*, e a variância, σ_{T+1}^2 , é um desvio quadrático entre

estas projeções para garantir que a previsão híbrida permanece dentro do intervalo limitado por estas previsões. A partir do método de simulação de Monte Carlo foi possível gerar amostras de \hat{y}_{T+1}^{bt} para cada tempo no horizonte de previsão. As etapas de implementação do algoritmo pode ser descrito de forma resumida, como segue:

Etapa 1: *Previsão para a série Brasil.*

Passo 2: *Prever cada série na base e agregar para níveis superiores até a série totalmente agregada.*

Etapa 3: *Crie um vetor contendo a média μ_{T+1} entre cada previsão top-down e bottom-up obtida na etapa 1 e na etapa 2.*

Passo 4: *Crie um vetor contendo a variância σ_{T+1}^2 entre cada previsão top-down e bottom-up obtida em a etapa 1 e a etapa 2.*

Etapa 5: *Gere uma amostra de tamanho n a partir de uma distribuição normal com média μ_{T+1} e variância σ_{T+1}^2 para cada T .*

Etapa 6: *Crie um vetor de previsão da abordagem híbrida contendo a média de cada amostra obtida na etapa 5 na ordem temporal.*

Portanto, para gerar as previsões h passos à frente, basta repetir o processo descrito acima. Também estão apresentadas no fluxograma 4.2 as etapas da metodologia utilizada para gerar as previsões da abordagem híbrida.

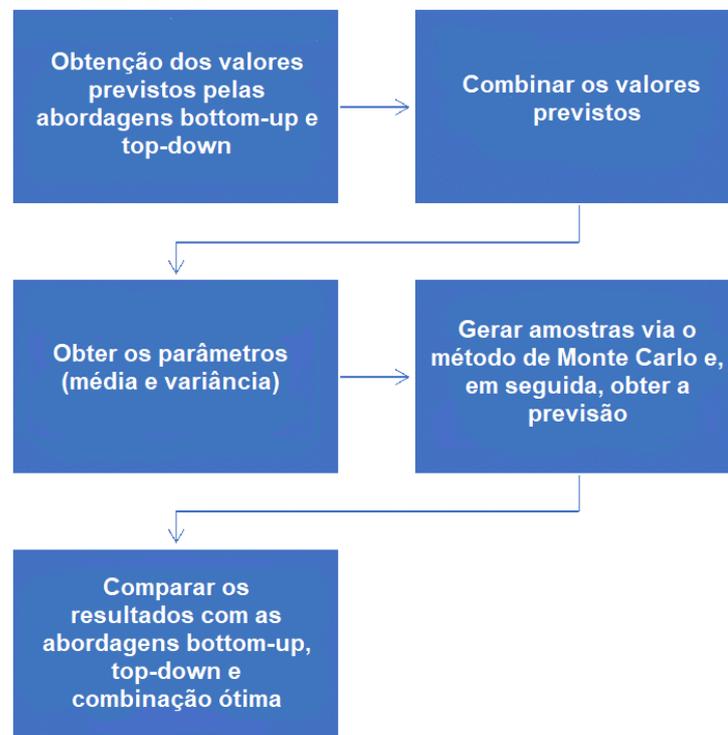


Figura 4.2 – Fluxograma com as etapas da metodologia da abordagem híbrida.

Fonte: Autor (2023)

Análise Exploratória dos Dados

5.1 Brasil e Regiões

Na tabela 5.1, tem-se algumas medidas estatísticas de cada ano analisado do consumo mensal de energia elétrica do setor industrial brasileiro (EPE, 2022a).

Tabela 5.1 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial brasileiro em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação %
2004	12846,83	291560,70	539,96	11829,00	13414,00	4,20
2005	13217,33	133968,42	366,02	12496,00	13601,00	2,77
2006	13598,42	149381,17	386,50	12851,00	14164,00	2,84
2007	14530,67	222010,42	471,18	13592,00	15025,00	3,24
2008	14652,83	404200,70	635,77	13417,00	15412,00	4,34
2009	13483,17	710177,42	842,72	11924,00	14552,00	6,25
2010	14956,58	380298,81	616,68	13425,00	15456,00	4,12
2011	15298,00	187278,18	432,76	14467,00	15853,00	2,83
2012	15285,42	112891,36	335,99	14567,00	15628,00	2,20
2013	15390,25	197482,39	444,39	14370,00	15886,00	2,89
2014	14925,42	68056,63	260,88	14537,00	15260,00	1,75
2015	14071,50	127615,73	357,23	13327,00	14565,00	2,54
2016	13687,75	174712,57	417,99	12538,00	14136,00	3,05
2017	13903,92	138837,36	372,61	13105,00	14316,00	2,68
2018	14121,92	119368,63	345,50	13525,00	14539,00	2,45
2019	13858,17	71473,42	267,35	13442,00	14306,00	1,93
2020	13802,42	1019275,90	1009,59	12173,00	15109,00	7,31
2021	15134,92	125320,45	354,01	14346,00	15552,00	2,34

A partir de 2004 a taxa de consumo de energia elétrica aumentou em alguns anos reduziu em outros período da série histórica (Figura 5.1).

Em 2014, o Brasil teve a menor variância em seus dados, já em 2020, foi o ano em que o Brasil teve maior variância. Comparando anos de 2020 e 2021, na tabela 5.1, ocorreu um aumento, em média, no consumo de energia elétrica por parte de suas indústrias, aumento de 1332,5 GWh. O valor mínimo de 2004 é o menor dado do conjunto, isso pode indicar que apesar das variações, o setor industrial brasileiro cresce a sua demanda energética.

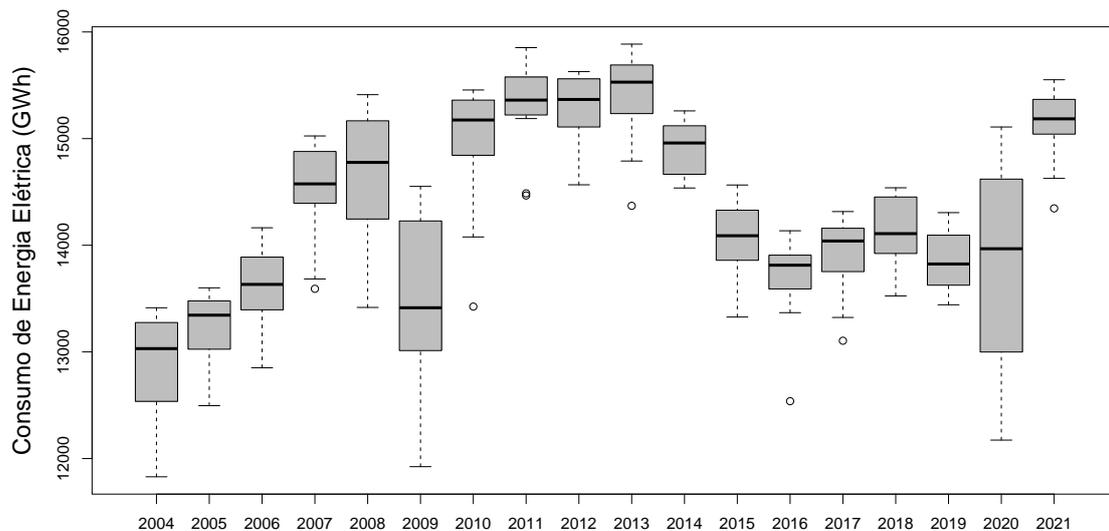


Figura 5.1 – Box-plot dos dados do consumo de energia elétrica do setor industrial brasileiro por ano.

Fonte: Autor (2022)

Na figura 5.1 foi construído o gráfico de box-plot para cada ano da série histórica de consumo de energia elétrica do setor industrial brasileiro. Pode-se constatar que nos anos de 2011 e 2013 a indústria consumiu mais energia elétrica e no ano de 2020 teve a maior variância em seu consumo pelo tamanho do intervalo interquartil. É perceptível a presença de alguns *outliers*, principalmente no ano de 2011. As flutuações dos gráficos indicam muitas mudanças de nível, ou seja, tendência variável. De acordo com a EPE, em 2009 ocorreu uma crise econômica mundial que impactou no consumo de energia elétrica do setor industrial como pode ser observado na figura 5.1. Em 2014 também ocorreu um crise econômica e em 2020, a pandemia de COVID-19, causando, também, nas reduções do consumo de energia elétrica como pode ser observado na figura 5.1.

Na tabela 5.2, tem-se as medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Norte. Desde 2004 até 2012 nota-se um crescimento da média dos dados, apesar do deficit em 2015, o crescimento se sucede até 2017. Assim, verificou-se um crescimento no consumo de energia neste período. O coeficiente de variação de 2015 foi o menor em comparação aos outros anos.

Tabela 5.2 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Norte em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	905,83	2483,06	49,83	810,00	979,00	5,50
2005	935,17	686,15	26,19	894,00	980,00	2,80
2006	987,17	1287,97	35,89	899,00	1028,00	3,64
2007	1036,50	1800,09	42,43	940,00	1089,00	4,09
2008	1066,25	1668,75	40,85	995,00	1142,00	3,83
2009	1030,92	2088,08	45,70	913,00	1079,00	4,43
2010	1105,42	1810,45	42,55	1006,00	1154,00	3,85
2011	1185,42	2020,81	44,95	1073,00	1250,00	3,79
2012	1189,33	2166,97	46,55	1123,00	1289,00	3,91
2013	1181,33	3615,15	60,13	1060,00	1288,00	5,09
2014	1235,67	1031,52	32,12	1152,00	1266,00	2,60
2015	1240,50	1577,36	39,72	1144,00	1284,00	3,20
2016	1240,92	1378,81	37,13	1197,00	1304,00	2,99
2017	1266,67	2451,52	49,51	1145,00	1322,00	3,91
2018	1100,50	11356,09	106,56	1000,00	1311,00	9,68
2019	1115,08	10193,17	100,96	928,00	1255,00	9,05
2020	1210,00	5448,18	73,81	1071,00	1312,00	6,10
2021	1316,33	1674,97	40,93	1212,00	1367,00	3,11

O consumo de energia elétrica das indústrias na região Norte possui uma tendência de crescimento entre os anos de 2004 e 2017 (figura 5.2). Nos anos de 2018 à 2020 a variabilidade dos dados é significativa.

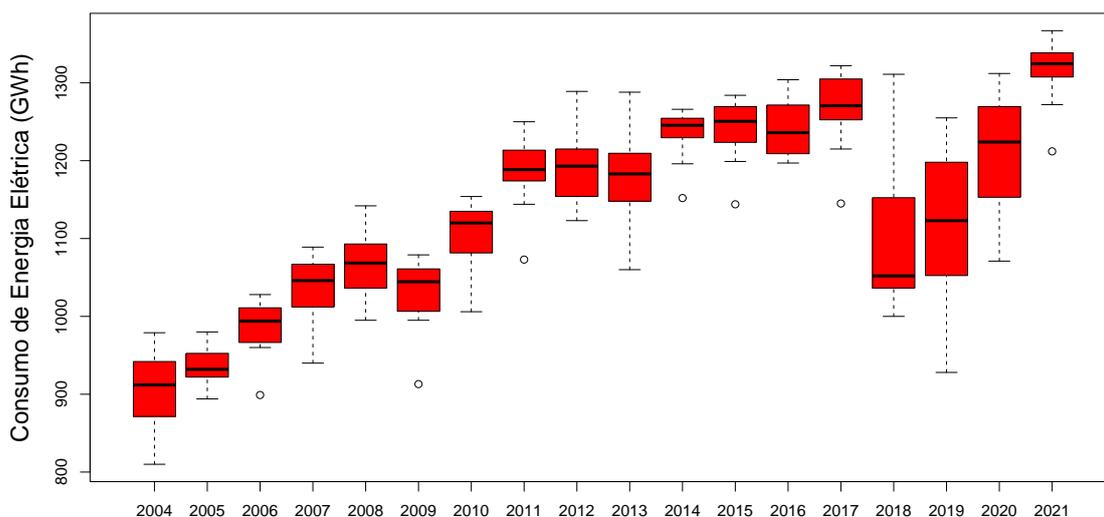


Figura 5.2 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Norte.

Fonte: Autor (2022)

Na tabela 5.3, tem-se as medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Nordeste. A média dos dados da região Nordeste passaram por algumas oscilações ao longo dos anos, contudo, houve uma queda de 2016 à 2020. Em 2012, o consumo de energia elétrica teve o menor coeficiente de variação. A queda da média do consumo entre os anos de 2004 à 2021 foi de 9,13%. Na região Nordeste, figura 5.3 observa-se uma queda entre 2013 à 2021.

Tabela 5.3 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Nordeste em GWh.

	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	2125,58	8305,17	91,13	1942,00	2234,00	4,29
2005	2192,33	5607,70	74,88	2013,00	2292,00	3,42
2006	2262,25	7169,48	84,67	2066,00	2385,00	3,74
2007	2406,42	12802,08	113,15	2151,00	2545,00	4,70
2008	2466,92	5544,08	74,46	2333,00	2556,00	3,02
2009	2290,75	11682,39	108,09	2100,00	2450,00	4,72
2010	2465,75	5593,48	74,79	2319,00	2575,00	3,03
2011	2395,08	12718,63	112,78	2101,00	2549,00	4,71
2012	2408,42	3696,27	60,80	2275,00	2480,00	2,52
2013	2393,67	4471,88	66,87	2275,00	2479,00	2,79
2014	2249,17	4733,97	68,80	2103,00	2364,00	3,06
2015	2050,75	11166,75	105,67	1894,00	2267,00	5,15
2016	1944,25	3078,02	55,48	1871,00	2024,00	2,85
2017	1826,42	4332,63	65,82	1697,00	1908,00	3,60
2018	1865,08	9517,72	97,56	1635,00	1976,00	5,23
2019	1811,08	4097,17	64,01	1676,00	1905,00	3,53
2020	1761,33	21008,24	144,94	1450,00	1989,00	8,23
2021	1931,50	3104,45	55,72	1819,00	2010,00	2,88

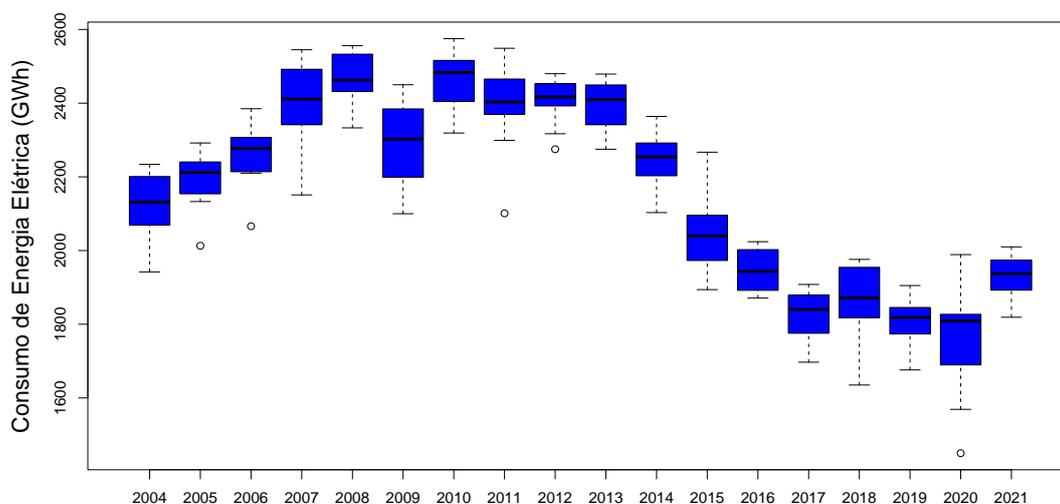


Figura 5.3 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Nordeste.

Fonte: Autor (2022)

Na tabela 5.4, tem-se as medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Centro-Oeste. Esta região possui a menor variação entre os dados ano a ano em comparação com as outras regiões. A média dos dados vem crescendo ao longo do tempo, isso indica que a demanda energética para esta região vem crescendo ao longo dos anos. De 2004 à 2021, em média, a demanda energética das indústrias da região Centro-Oeste aumentou aproximadamente 1,016 %.

Tabela 5.4 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Centro-Oeste em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	428,33	1314,24	36,25	364,00	474,00	8,46
2005	445,42	804,63	28,37	399,00	502,00	6,37
2006	448,83	364,33	19,09	413,00	486,00	4,25
2007	474,83	558,15	23,63	442,00	515,00	4,98
2008	516,42	1358,27	36,85	464,00	567,00	7,14
2009	536,83	1572,52	39,65	449,00	601,00	7,39
2010	545,17	393,06	19,83	516,00	575,00	3,64
2011	633,92	3247,72	56,99	525,00	698,00	8,99
2012	712,17	812,15	28,50	677,00	761,00	4,00
2013	767,75	2230,02	47,22	684,00	830,00	6,15
2014	772,58	1486,08	38,55	713,00	838,00	4,99
2015	716,83	929,79	30,49	658,00	781,00	4,25
2016	722,33	529,33	23,01	686,00	764,00	3,19
2017	730,33	816,61	28,58	664,00	762,00	3,91
2018	757,42	1403,72	37,47	693,00	819,00	4,95
2019	781,25	1206,20	34,73	729,00	831,00	4,45
2020	843,33	2089,15	45,71	764,00	917,00	5,42
2021	863,58	1046,81	32,35	801,00	900,00	3,75

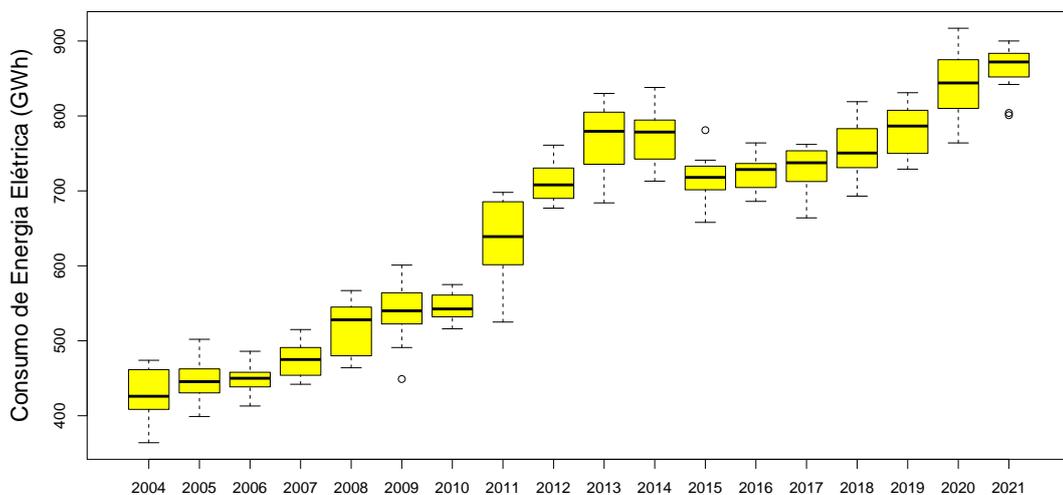


Figura 5.4 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Centro-Oeste.

Fonte: Autor (2022)

Na região Centro-Oeste fica explícito que através dos anos a variância do consumo de energia elétrica é baixa (veja figura 5.4). Diferente do consumo de energia para o Brasil, que possui uma tendência variada, a tendência da região Centro-Oeste é de crescimento ao longo dos anos. Fato interessante nesta região é a presença de poucos *outliers*, além disso em 2020, em ano pandêmico, as indústrias do Centro-Oeste tiveram seu maior consumo de energia elétrica.

A tabela 5.5 apresenta as medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Sudeste. O consumo médio cresce no período de 2004 à 2013 e, em seguida tem uma queda até 2015 e retorna o crescimento até o ano de 2021. O ano de 2011, teve o menor coeficiente de variação em comparação aos outros anos analisados, 2,13%.

Tabela 5.5 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Sudeste em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	7298,50	97611,36	312,43	6798,00	7687,00	4,28
2005	7546,92	53126,99	230,49	7143,00	7858,00	3,05
2006	7741,33	43176,97	207,79	7353,00	8027,00	2,68
2007	8331,33	61553,70	248,10	7829,00	8655,00	2,98
2008	8209,67	155172,42	393,92	7399,00	8716,00	4,80
2009	7377,83	292957,79	541,26	6430,00	8104,00	7,34
2010	8375,58	173549,36	416,59	7349,00	8726,00	4,97
2011	8531,75	33073,11	181,86	8236,00	8796,00	2,13
2012	8398,92	49914,81	223,42	7968,00	8642,00	2,66
2013	8353,08	54205,17	232,82	7819,00	8670,00	2,79
2014	7953,67	40533,52	201,33	7587,00	8268,00	2,53
2015	7473,33	47686,24	218,37	7022,00	7809,00	2,92
2016	7232,00	63348,36	251,69	6555,00	7469,00	3,48
2017	7393,50	51283,18	226,46	6930,00	7721,00	3,06
2018	7680,42	47805,36	218,64	7309,00	7998,00	2,85
2019	7398,42	25329,54	159,15	6960,00	7581,00	2,15
2020	7276,67	313772,61	560,15	6323,00	7887,00	7,70
2021	8031,58	38293,90	195,69	7666,00	8360,00	2,44

A figura 5.5 mostra os gráficos box-plot do consumo anual de energia elétrica do setor industrial na região Sudeste. Pode-se observar nesta figura uma semelhança no comportamento da série temporal com a série nível Brasil, já que, além das mudanças de nível, os anos de 2009 e 2020 apresentaram alta variabilidade.

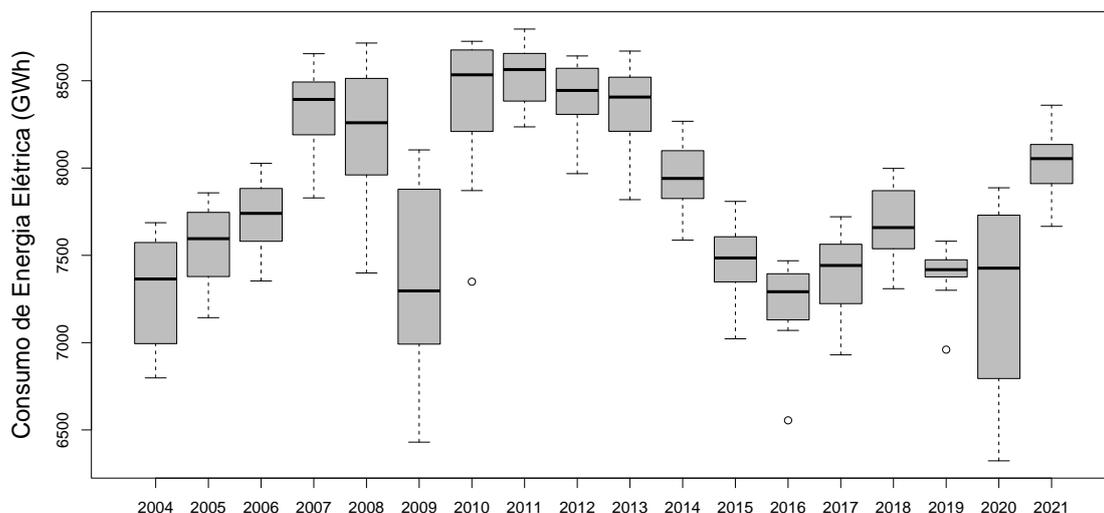


Figura 5.5 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Sudeste.

Fonte: Autor (2022)

Na tabela 5.6, tem-se as medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da região Sul. A variância dessa região é considerável, e a média dos dados tem uma tendência de crescimento ao longo dos anos.

Tabela 5.6 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial da Região Sul em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	2088,50	14753,36	121,46	1811,00	2223,00	5,82
2005	2097,83	6590,88	81,18	1867,00	2171,00	3,87
2006	2158,83	7759,97	88,09	1916,00	2263,00	4,08
2007	2281,83	12367,79	111,21	1974,00	2379,00	4,87
2008	2393,67	18206,61	134,93	2119,00	2519,00	5,64
2009	2247,00	26757,64	163,58	1818,00	2408,00	7,28
2010	2464,58	15170,99	123,17	2104,00	2557,00	5,00
2011	2551,83	10725,06	103,56	2264,00	2651,00	4,06
2012	2576,42	11682,08	108,08	2277,00	2690,00	4,20
2013	2694,67	19584,42	139,94	2301,00	2832,00	5,19
2014	2714,08	11070,81	105,22	2423,00	2824,00	3,88
2015	2590,00	11386,73	106,71	2362,00	2753,00	4,12
2016	2548,42	14084,99	118,68	2192,00	2648,00	4,66

Continua na próxima página.

Continuação da Tabela 5.6

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2017	2686,92	12379,90	111,27	2376,00	2799,00	4,14
2018	2718,08	13213,54	114,95	2498,00	2861,00	4,23
2019	2752,33	7166,97	84,66	2570,00	2841,00	3,08
2020	2710,83	53393,06	231,07	2374,00	3004,00	8,52
2021	2991,75	7914,93	88,97	2829,00	3090,00	2,97

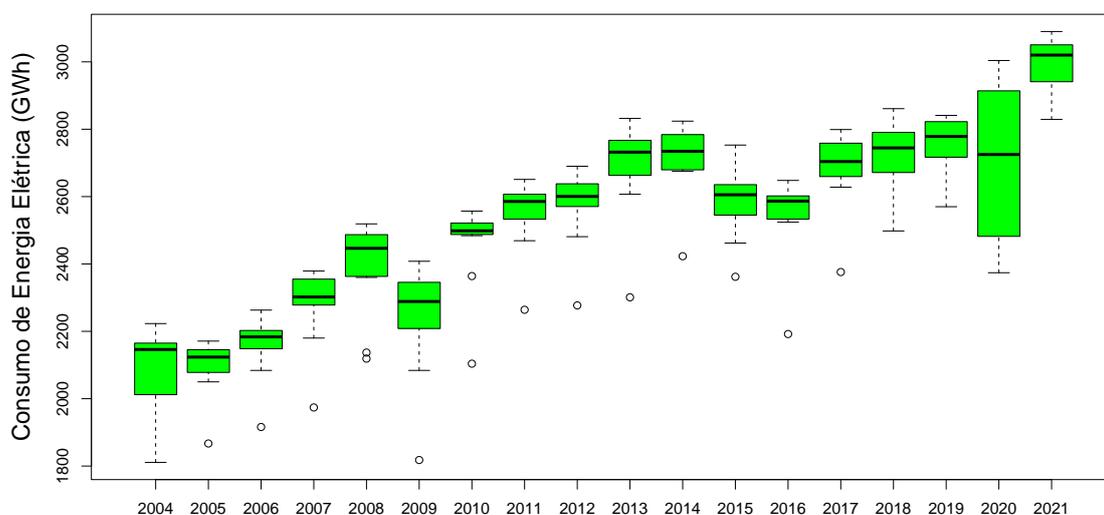


Figura 5.6 – Box-plot dos dados do consumo de energia elétrica do setor industrial da região Sul.

Fonte: Autor (2022)

A figura 5.6 apresenta os box-plot anual dos dados de consumo de energia elétrica do setor industrial da região Sul. O ano de 2020 exibiu alta variabilidade em seus dados em comparação com os demais anos. As posições dos box-plot ao longo dos anos exibem uma tendência de crescimento do consumo de energia.

A figura 5.7 mostra trajetória do consumo de energia elétrica do setor industrial brasileiro e regiões geográficas. A característica sazonal presente nos dados nacionais também está contida nos dados regionais, em particular, a sazonalidade da região Sudeste acompanha razoavelmente o mesmo comportamento dos dados nacionais, além disso, é a região que as indústrias mais consomem energia elétrica. O setor industrial da região Centro-Oeste é que menos consome energia elétrica. Os dados da região Nordeste ocupava a segunda posição no quesito consumo energético, contudo, após uma redução considerável em seu consumo, no ano de 2010 perdeu a posição para a região Sul.

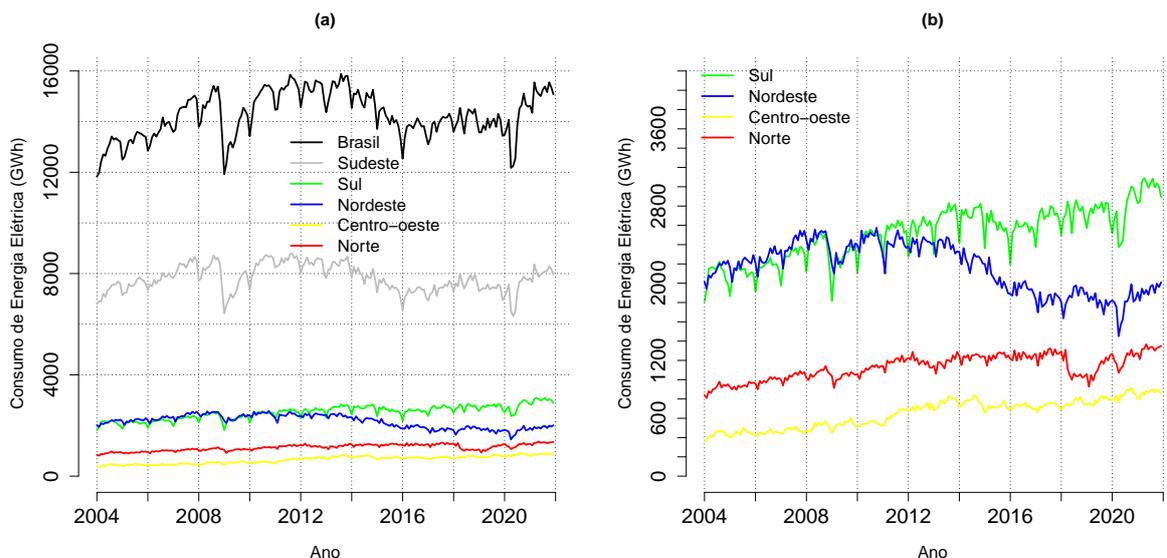


Figura 5.7 – (a) Séries temporais do consumo do setor industrial brasileiro e regiões. (b) Séries temporais do consumo do setor industrial das regiões Sul, Nordeste, Centro-Oeste e Norte.

Fonte: Autor (2022)

A figura 5.8 apresenta os gráficos de box-plot mensal para série temporal. Pode-se constatar algumas flutuações nas medianas dos box-plot ao longo dos conjuntos mensais. Essa flutuações caracterizam o comportamento sazonal das séries, além disso, exibe que as séries não são estacionárias.

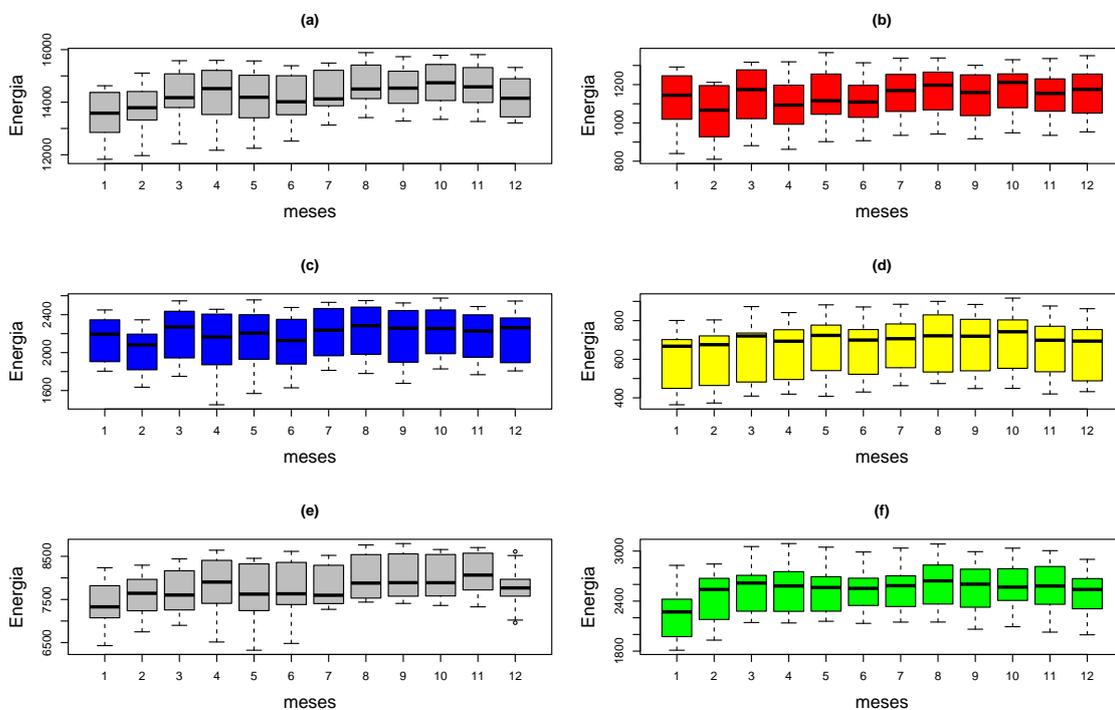


Figura 5.8 – Box-plot dos dados mensal do consumo de energia elétrica do setor industrial: (a) brasileiro; (b) da região Norte; (c) da região Nordeste; (d) da região Centro-Oeste; (e) da região Sudeste; (f) da região Sul.

Fonte: Autor (2022)

No setor industrial brasileiro, a mediana de consumo do mês de janeiro é menor que os outros meses e é visível que ocorre um aumento no consumo entre janeiro e abril, logo depois, uma leve queda de abril à junho e uma retomada no consumo até novembro. Os meses de abril, agosto e outubro têm os maiores consumos de energia elétrica. No setor industrial da região Norte, observa-se oscilações da mediana entre os três primeiros meses do ano. De janeiro à fevereiro os dados, em média, decresceram e retomaram no mês subsequente. Depois, os dados apresentaram pequenas oscilações ao longo dos meses. O mês de fevereiro e abril possuem baixos consumos de energia elétrica, já o mês de março e agosto possuem os mais altos. No setor industrial da região Nordeste, de junho à dezembro é notório uma leve estabilidade na média dos dados, entretanto, nos primeiros meses é visível algumas oscilações. O mês de fevereiro possui o menor consumo de energia e março e agosto possuem os mais altos.

Os meses de maio, agosto e outubro possuem os maiores consumo de energia elétrica por parte do setor industrial da região Centro-Oeste. É visível um aumento no consumo entre os meses de agosto à outubro, além disso, o mês de janeiro possui o menor consumo de energia elétrica. Na região Sudeste destaca-se o mês de dezembro, como o mês de menor variabilidade do consumo além de uma visível queda no consumo energético em comparação com o mês anterior, essa queda continua até o início de um novo ano e o consumo volta a aumentar a partir de fevereiro. Os meses de julho à novembro são de alto consumo de energia elétrica, o mesmo destaque é dado para o mês de abril. A sazonalidade nos dados de consumo de energia elétrica na região sul tem o seguinte comportamento: no início do ano o consumo tende a ser reduzido e ocorre um aumento nos três meses subsequentes, uma arrefecida de maio à julho e volta a crescer nos meses seguintes até novembro.

Na tabela 5.7, observa-se o grau de correlação entre os dados a nível Brasil e suas regiões e na figura 5.9 os respectivos gráficos de dispersão associando cada variável com a outra.

Tabela 5.7 – Tabela contendo o nível de correlação entre os dados nacionais e regionais de consumo de energia elétrica do setor industrial.

	Brasil	Norte	Nordeste	Sul	Centro-Oeste	Sudeste
Brasil	1.00	0.53	0.49	0.62	0.41	0.90
Norte	0.53	1.00	-0.24	0.78	0.81	0.15
Nordeste	0.49	-0.24	1.00	-0.33	-0.49	0.70
Sul	0.62	0.78	-0.33	1.00	0.90	0.27
Centro-Oeste	0.41	0.81	-0.49	0.90	1.00	0.00
Sudeste	0.90	0.15	0.70	0.27	0.00	1.00

Pode-se observar na figura 5.9 e na tabela 5.7 que os dados de consumo nacional possuem alta correlação com os dados da região Sudeste. Isso mostra a importância desta região no cenário nacional, já que alterações nos dados da região Sudeste influenciam drasticamente no consumo energético do Brasil. Também destaca-se a relação entre a região Nordeste com a região Sudeste e consequentemente o Brasil. A região Nordeste possui uma correlação considerável com a região Sudeste. Não existe qualquer relação significativa entre os dados da região Centro-Oeste e Sudeste, isso também pode ser verificado pelo gráfico de dispersão.

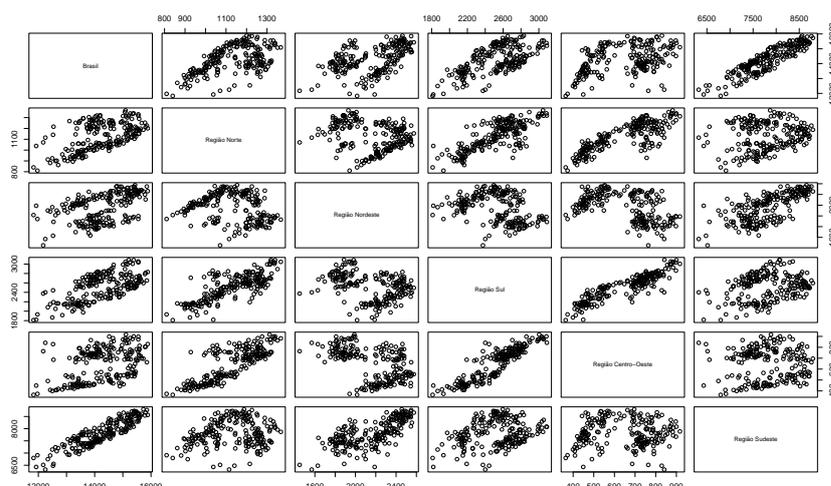


Figura 5.9 – Gráfico de dispersão entre os dados de consumo de energia elétrica do setor industrial brasileiro e suas respectivas regiões.

Fonte: Autor (2022)

5.2 Região Norte

Nesta seção será exibida uma análise exploratória para o consumo de energia elétrica dos estados da região Norte, sendo: Acre, Amapá, Amazonas, Pará, Roraima, Rondônia e Tocantins. As tabelas 5.8 e 5.9 apresenta o resumo estatístico dos dados dos estados da região Norte nos anos de 2019 e 2020. As tabelas completas se encontram no anexo.

Tabela 5.8 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Norte em GWh para o ano de 2019.

Estado	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Acre	3,11	0,12	0,35	2,56	3,49	11,20
Amapá	8,84	0,45	0,67	7,78	9,72	7,59
Amazonas	137,82	83,88	9,16	123,69	150,91	6,65
Pará	899,36	9152,35	95,67	736,77	1055,86	10,64
Roraima	1,90	0,10	0,31	1,47	2,42	16,37
Rondônia	37,95	1,73	1,31	36,01	40,50	3,47
Tocantins	27,04	6,42	2,53	21,62	30,76	9,37

O estado do Acre possui um PIB industrial de 998 milhões de reais, este valor equivale à 0,1% da indústria nacional. Possui o segundo menor PIB do Brasil e emprega 12.341 trabalhadores na indústria. Os principais setores industriais no estado são: construção (54,6%); alimentos (19,1%); serviços industriais de utilidade pública (16,4%); madeira (3,2%) e minerais não metálicos (2,2%) (CNI, 2022m).

Na figura 5.10 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado do Acre. É perceptível mudanças de nível na série temporal, este comportamento é visto através das posições das medianas nos box-plots. Existe presença de *outliers* em 2017 mesmo com um pequeno intervalo interquartil, ademais, não existe grande variação no tamanho das caixas, indicando que a variação nos dados ano a ano não se altera de maneira drástica.

Tabela 5.9 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Norte em GWh para o ano de 2020.

Estado	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Acre	3,41	0,05	0,23	3,07	3,77	6,77
Amapá	8,89	1,55	1,24	5,51	10,33	14,01
Amazonas	138,45	432,11	20,79	91,78	160,11	15,01
Pará	991,20	3006,25	54,83	905,45	1064,69	5,53
Roraima	1,88	0,04	0,19	1,55	2,13	10,22
Rondônia	39,28	6,83	2,61	34,96	42,68	6,65
Tocantins	27,15	11,69	3,42	20,65	31,05	12,60

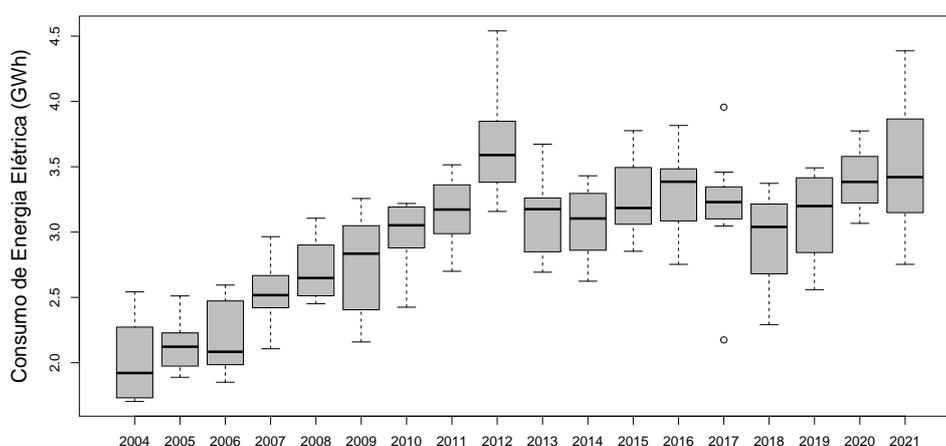


Figura 5.10 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Acre.

Fonte: Autor (2022)

O estado do Amazonas possui um PIB industrial de 33 bilhões de reais, equivalente a 2,4% da indústria nacional, além disso, emprega 127.406 trabalhadores na indústria. É o décimo segundo menor PIB do Brasil e é o 13º estado mais populoso do país, com 4,3 milhões de habitantes. Os principais setores da indústria amazonense são de informática, eletrônicos e ópticos (19,2%); serviços industriais de utilidade pública (13,4%), bebidas (12,6%), construção (9,4%) e equipamentos de transporte (7,6%), os setores principais equivalem a 62,2% da indústria do estado (CNI, 2022n).

Na figura 5.11 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado do Amazonas. A tendência possui mudanças de nível e entre os anos de 2017 a 2021 os gráficos apresentam uma tendência de crescimento. Além disso a calda do box-plot nos dados do ano de 2016 são bastante grandes em comparação aos demais.

O estado de Rondônia possui um PIB industrial de 6,9 bilhões de reais e equivale a 0,5% da indústria nacional, além disso emprega 48.746 trabalhadores. É o sexto menor PIB do Brasil e é o 5º estado menos populoso, com 1,8 milhões de habitantes. Os principais setores da indústria no estado são serviços industriais de utilidade pública (49,3%); construção (21,5%); alimentos (19,9%), madeira (2,2%) e minerais não metálicos (1,1%) (CNI, 2022g).

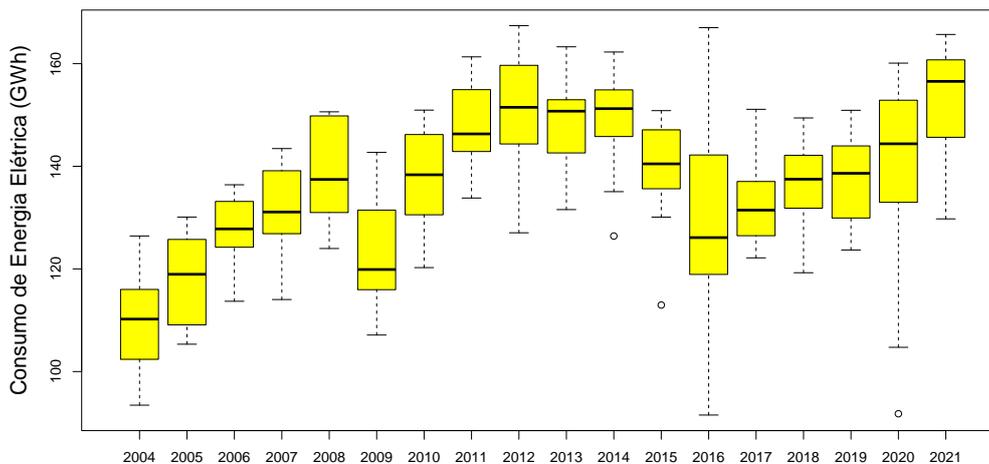


Figura 5.11 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Amazonas.

Fonte: Autor (2022)

Na figura 5.12 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado de Rondônia. O consumo de energia possui baixa variabilidade ao longo dos anos além de um pico no consumo entre os anos de 2012 e 2013.

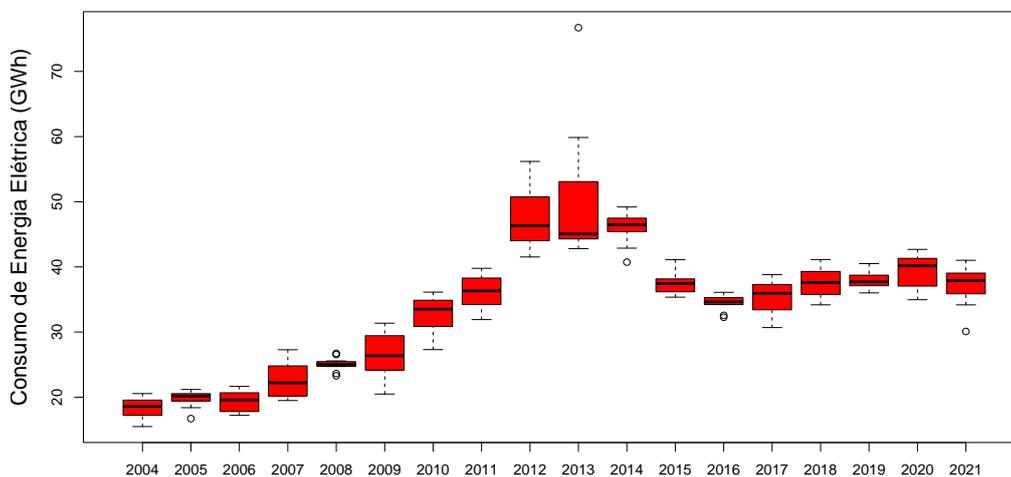


Figura 5.12 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Rondônia.

Fonte: Autor (2022)

O estado de Roraima possui um PIB industrial de 1 bilhão de reais, equivalente a 0,1% da industrial nacional e emprega 9.358 trabalhadores da indústria. É o menor PIB do Brasil e é o estado menos populoso do país, com 652 mil habitantes. Os principais setores industriais do estado são: construção (64,6%); serviços industriais de utilidade pública (20,7%); alimentos (6,9%); minerais não metálicos (2,2%) e extração de minerais não-metálicos (1,4%) (CNI, 2022h).

Na figura 5.13 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado de Roraima. O consumo possui algumas mudanças de nível, contudo, não existe a clara presença de tendência em toda a série, apesar de ocorrer entre os anos de 2015 e 2018 uma tendência de crescimento.

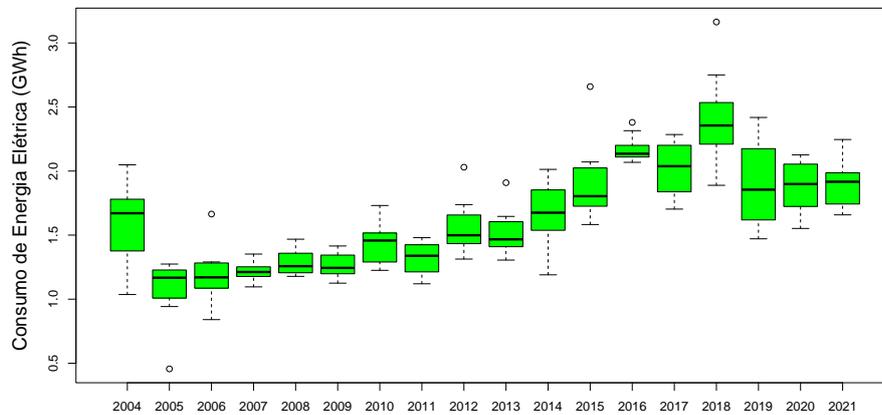


Figura 5.13 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Roraima.

Fonte: Autor (2022)

O estado do Pará possui um PIB industrial de 55,5 bilhões que é equivalente a 4,0% da indústria nacional. As indústrias empregam 179.396 trabalhadores e é o décimo PIB do Brasil. O estado possui 8,8 milhões de habitantes e é o 9º estado mais populoso do país. Os principais setores do estado são: extração de minerais metálicos (57,4%); serviços industriais de utilidade pública (18,2%), construção (13,6%); alimentos (3,4%) e metalurgia (2,8%) (CNI, 2022g).

Na figura 5.14 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado do Pará. Existe uma tendência de crescimento entre os anos de 2004 a 2017, depois da queda no consumo em 2018, houve uma retomada nos anos subsequentes.

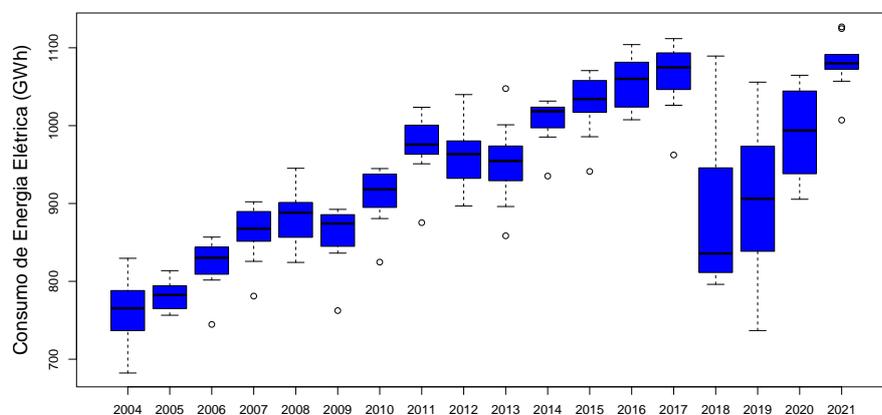


Figura 5.14 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Pará.

Fonte: Autor (2022)

O estado do Amapá possui PIB industrial de 1,5 bilhões de reais, equivalente a 0,1% do PIB industrial nacional. Emprega 8.267 trabalhadores e possui o terceiro menor PIB do Brasil. Possui uma população de 878 mil habitantes e é o segundo estado menos populoso do país. Os principais setores industriais do estado são: serviços industriais de utilidade pública (47,6%); construção (36,4%); alimentos (1,5%); químicos (0,9%) e móveis (0,5%) (CNI, 2022n).

Na figura 5.15 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado do Amapá. Existe uma tendência de crescimento no consumo apesar das mudanças de nível.

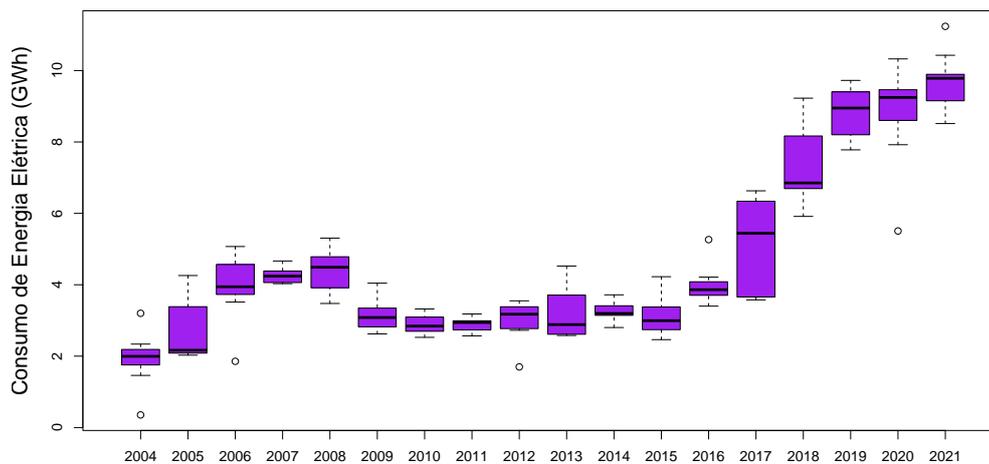


Figura 5.15 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Amapá.

Fonte: Autor (2022)

O estado do Tocantins possui um PIB industrial de 4,2 bilhões de reais, isso equivale a 0,3% da indústria nacional. Ademais, emprega 29.330 trabalhadores e é o quarto menor PIB do Brasil. Tocantins possui uma população de 1,6 milhões de habitantes e é o 4º estado menos populoso. Os principais setores da indústria do estado são: serviços industriais de utilidade pública (37,3%); construção (37,2%); alimentos (13,4%); derivados de petróleo e biocombustíveis (4,3%) e extração de minerais não-metálicos (2,5%) (CNI, 2022i).

Na figura 5.16 observa-se o gráfico box-plot do consumo anual de energia elétrica do setor industrial do estado do Tocantins. Existe uma perceptível tendência de crescimento nos dados do consumo de energia elétrica do setor industrial do estado do Tocantins. Em 2010, se encontra o único *outlier* entre os anos analisados. Em 2006, os dados possuem uma assimetria negativa. Entre 2004 e 2012 a variância dos dados ano a ano é baixa, doravante, é visto um aumento da variância ao longo dos anos subsequentes.

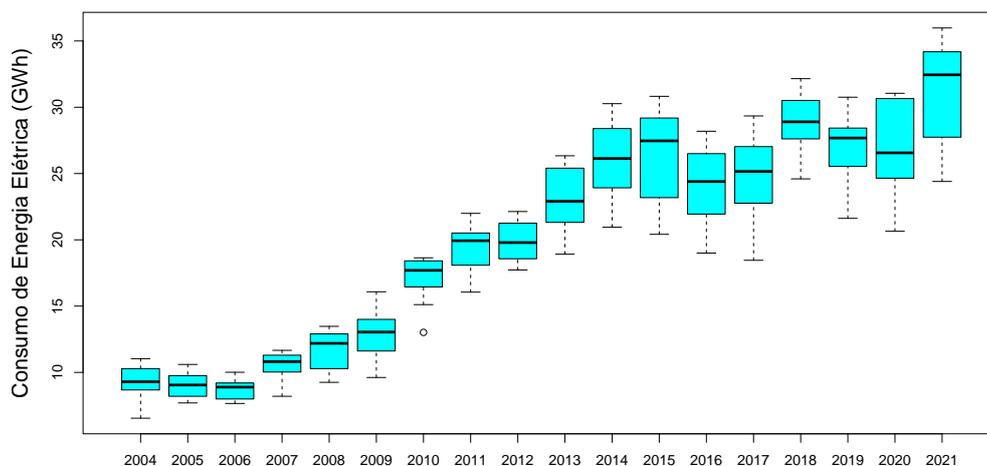


Figura 5.16 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Tocantins.

Fonte: Autor (2022)

Observe a figura 5.17 contendo os gráficos da série história dos dados de consumo de energia elétrica do setor industrial da região Norte em comparação com seus estados. A figura 5.18 contém os gráficos das séries temporais de estados da região norte com mais detalhamento. O setor industrial do Pará é o que mais consome energia elétrica na região Norte, seguido pelo Amazonas.

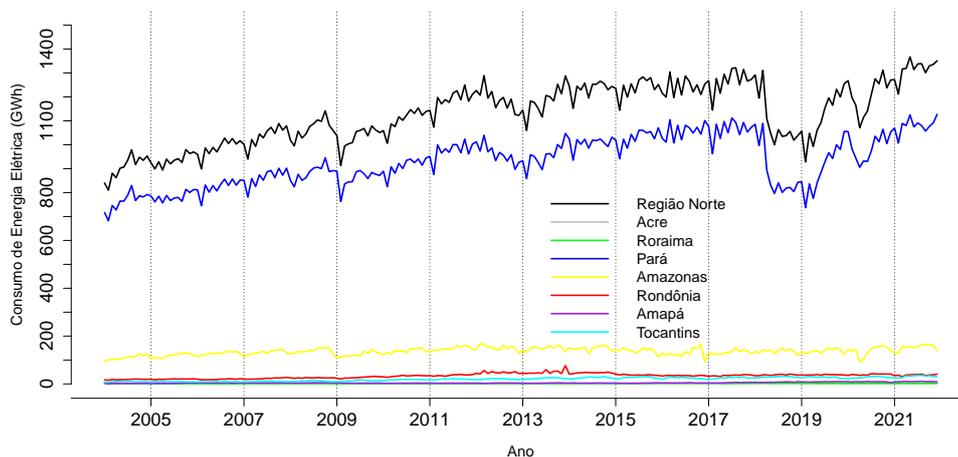


Figura 5.17 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Norte e seus estados.

Fonte: Autor (2022)

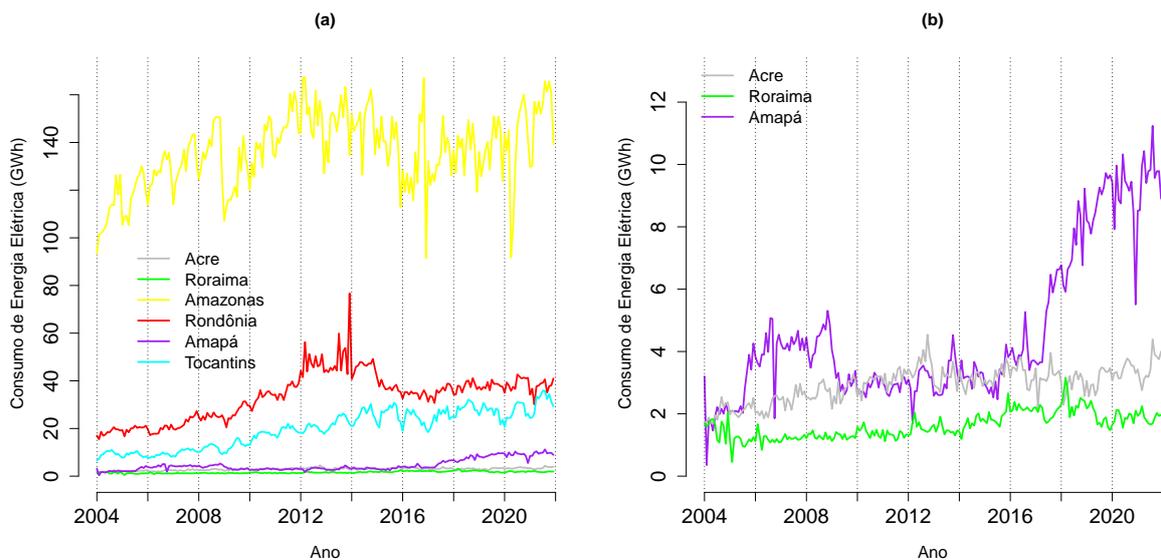


Figura 5.18 – (a) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de seis estados da região Norte. (b) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de três estados da região Norte.

Fonte: Autor (2022)

Todas as séries temporais possuem alguma sazonalidade e muitas mudanças de nível. A série de consumo do Pará tem um comportamento parecido com a região Norte, isso pode ser um indicativo que existe uma correlação entre os dados. O setor industrial de Roraima é o que menos consome energia elétrica. É visível um crescimento de 2015 à 2022 no consumo de energia no estado do Amapá. Entre 2013 e 2014 o estado de Rondônia teve um pico em seu consumo, comportamento discrepante em comparação com os outros meses analisados.

Observando os gráficos box-plot das séries históricas dos estados da região Norte ficou claro a presença de tendência na maioria dos casos. No estado de Rondônia foi verificado com um nível de confiança de 95% a presença de estacionalidade. Agora, analisando os gráficos box-plot mês a mês pode-se verificar comportamento sazonal. Veja as figuras 5.19 e 5.20:

Analisando os gráficos box-plot nas figuras 5.19 e 5.20 é perceptível que em alguns estados a sazonalidade é mais explícita. No estado do Amazonas os meses de agosto à novembro é o período que o setor industrial mais consome energia elétrica. Em Tocantins, o aumento do consumo ocorre em junho à agosto, ou seja, meses no meio do ano. Já em Roraima, as indústrias consomem mais energia em Abril e Maio. No Pará existem muitas oscilações na mediana dos dados mês a mês, contudo, é evidente uma queda no consumo em fevereiro. Os estados de Rondônia e Amapá não possui uma sazonalidade tão aparente quanto nos outros estados. No Acre é visível um aumento no consumo de julho à setembro.

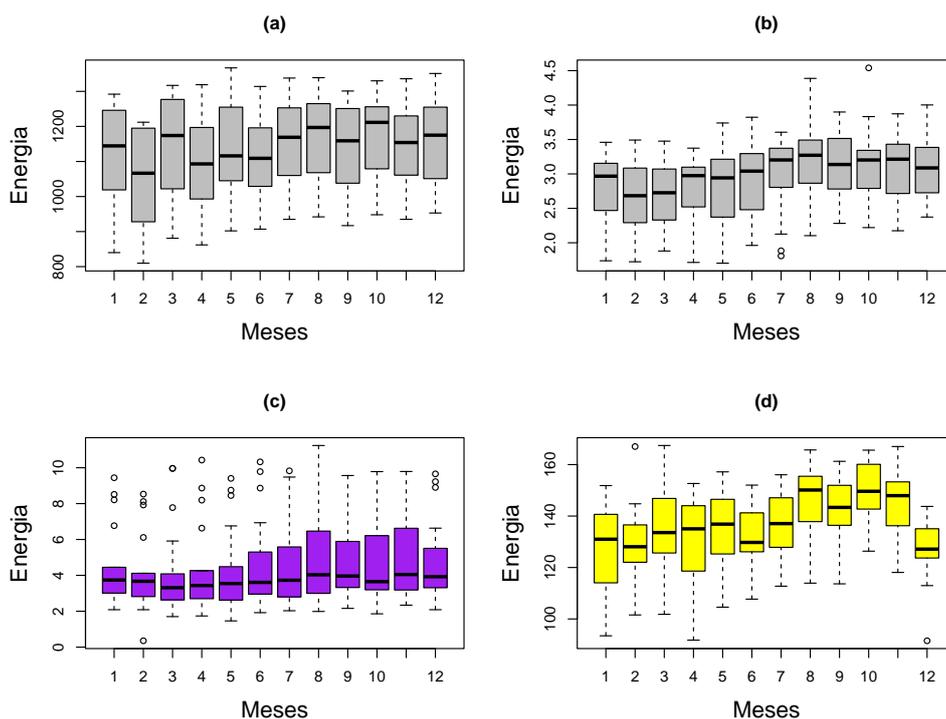


Figura 5.19 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Norte; (b) do Acre; (c) do Amapá; (d) do Amazonas.

Fonte: Autor (2022)

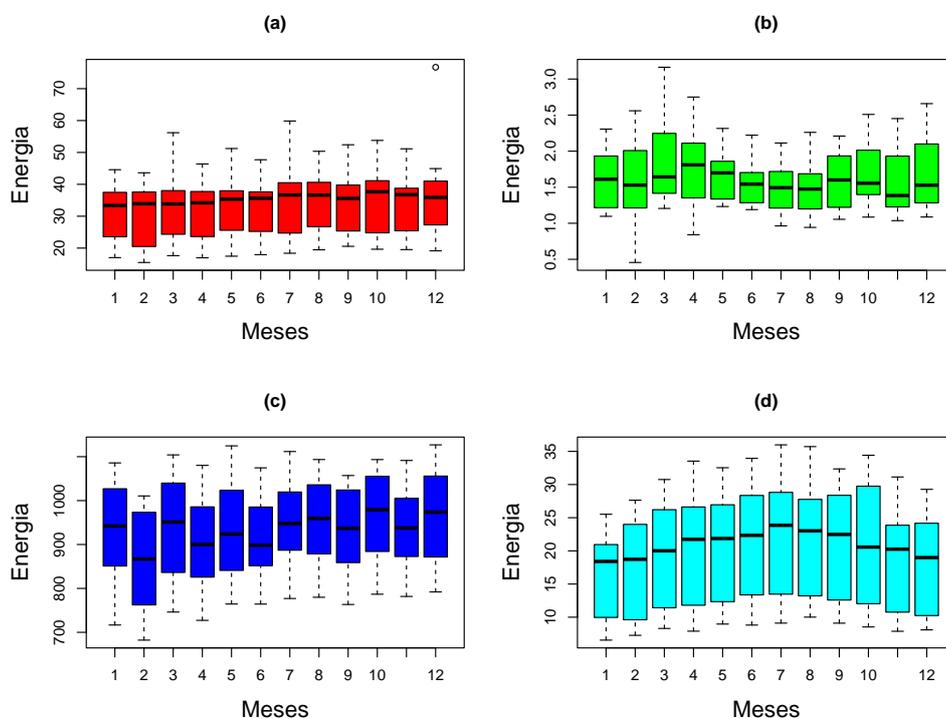


Figura 5.20 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) de Rondônia; (b) de Roraima; (c) do Pará; (d) do Tocantins.

Fonte: Autor (2022)

A tabela 5.10 exibe a correlação entre as séries temporais dos estados da região Norte, além da correlação da região com seus estados. O Pará possui uma alta correlação com a região Norte, isso implica que no quesito setor industrial, o estado mostra sua grande importância para a região. Por outro lado, o estado do Amapá entrega baixa correlação com a região Norte. Destaca-se a correlação entre os estados da região norte com o Tocantins, em geral, são consideráveis.

Tabela 5.10 – Tabela contendo o nível de correlação entre os dados da região Norte e seus estados de consumo de energia elétrica do setor industrial.

	Norte	Rondônia	Acre	Amazonas	Roraima	Pará	Amapá	Tocantins
Norte	1,00	0,73	0,76	0,64	0,46	0,98	0,35	0,77
Rondônia	0,73	1,00	0,72	0,62	0,40	0,63	0,23	0,75
Acre	0,76	0,72	1,00	0,61	0,36	0,70	0,39	0,72
Amazonas	0,64	0,62	0,61	1,00	0,10	0,53	0,25	0,51
Roraima	0,46	0,40	0,36	0,10	1,00	0,45	0,43	0,69
Pará	0,98	0,63	0,70	0,53	0,45	1,00	0,29	0,69
Amapá	0,35	0,23	0,39	0,25	0,43	0,29	1,00	0,59
Tocantins	0,77	0,75	0,72	0,51	0,69	0,69	0,59	1,00

5.3 Região Nordeste

Nesta seção será exibida uma análise exploratória de dados dos estados da região Nordeste. Os estados que compõe a região Nordeste são: Alagoas, Bahia, Ceará, Maranhão, Rio Grande do Norte, Sergipe, Paraíba, Pernambuco e Piauí. As tabelas 5.11 e 5.12 apresentam o resumo estatístico dos dados dos estados da região Nordeste nos anos de 2019 e 2020. As tabelas completas se encontram no anexo.

Tabela 5.11 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Nordeste em GWh para o ano de 2019.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Alagoas	84,96	1239,93	35,21	53,22	164,01	41,44
Bahia	769,16	1791,70	42,33	673,62	831,25	5,50
Ceará	208,66	253,80	15,93	171,26	228,58	7,64
Maranhão	129,04	157,53	12,55	104,85	144,24	9,73
Rio Gr. do Norte	100,11	13,79	3,71	93,94	105,43	3,71
Sergipe	90,28	16,63	4,08	86,06	100,75	4,52
Paraíba	120,10	17,43	4,18	113,01	127,99	3,48
Pernambuco	309,90	89,48	9,46	297,57	333,97	3,05
Piauí	17,33	3,28	1,81	13,50	19,43	10,45

Tabela 5.12 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Nordeste em GWh para o ano de 2020.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Alagoas	60,69	26,05	5,10	47,62	65,77	8,41
Bahia	765,15	2088,48	45,70	694,68	831,95	5,97
Ceará	183,72	1879,23	43,35	81,64	235,04	23,60
Maranhão	132,72	207,63	14,41	108,51	158,39	10,86
Rio Gr. do Norte	98,79	122,16	11,05	73,66	111,66	11,19
Sergipe	87,08	36,58	6,05	74,19	96,83	6,95
Paraíba	116,04	233,54	15,28	88,69	136,19	13,17
Pernambuco	299,67	844,89	29,07	233,05	340,74	9,70
Piauí	15,95	8,81	2,97	10,72	20,28	18,61

O setor industrial do estado de Alagoas possui um PIB industrial de 6,4 bilhões de reais, isso é equivalente a 0,5% da indústria brasileira. Emprega cerca de 95.144 trabalhadores e é o oitavo menor PIB do Brasil. Alagoas é o 10º estados menos populoso do Brasil com 3,4 milhões de habitantes. Os principais setores da indústria de Alagoas são: construção (30,1%); serviços industriais de utilidade pública (23,1%); alimentos (22%); químicos (6,9%) e derivados de petróleo e biocombustíveis (3,2%) (CNI, 2022c).

Na figura 5.21 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado de Alagoas. Entre os anos de 2017 e 2020 os gráficos indicam uma queda no consumo de energia. Nos anos de 2011, 2018 e 2019 o consumo apresentou alta variabilidade em comparação com os demais anos.

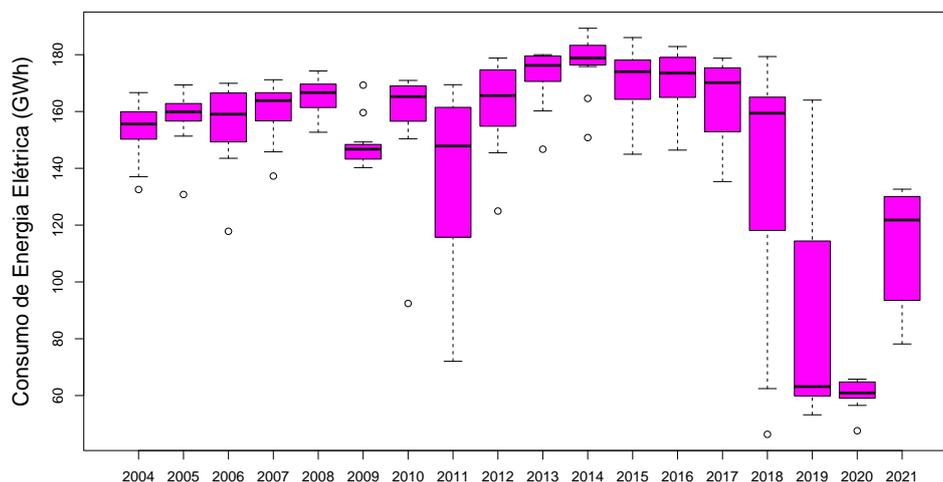


Figura 5.21 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Alagoas.

Fonte: Autor (2022)

O estado da Bahia possui um PIB industrial de 56 bilhões de reais, equivalente a 4% da indústria brasileira. Cerca de 361.709 trabalhadores estão empregados neste setor, além disso, o estado possui o sétimo PIB nacional e é o quarto estado mais populoso do Brasil, contendo 15

milhões de habitantes. Os principais setores industriais do estado são: construção (22,3%); serviços industriais de utilidade pública (19,1%); derivados de petróleo e biocombustíveis (16,5%); químicos (7,8%) e alimentos (5,2%) (CNI, 2022a).

Na figura 5.22 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado da Bahia. Em 2016, o intervalo interquartil é pequeno em relação aos outros gráficos, indicando baixa variância. Os gráficos não indicam uma tendência clara de crescimento no consumo.

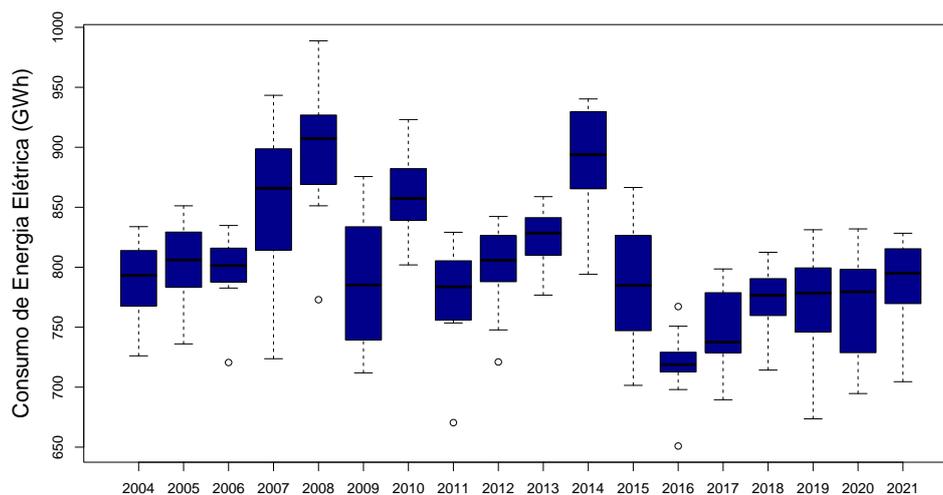


Figura 5.22 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Bahia.

Fonte: Autor (2022)

O estado do Ceará possui um PIB industrial de 24,4 bilhões de reais, que é equivalente a 1,8% da indústria brasileira. A indústria cearense emprega 300.661 trabalhadores, ademais, o estado possui o décimo segundo maior PIB do Brasil e é o 8º estado mais populoso do país, com 9,2 milhões de habitantes. Os principais setores industriais do estado são: construção (24,8%); serviços industriais de utilidade pública (22,6%); alimentos (9,9%); couros e calçados (9,2%) e metalurgia (5,3%) (CNI, 2022o).

Na figura 5.23 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado da Ceará. Em 2015, foi o único ano analisado que apresentou *outlier*. Os intervalos interquartis em sua maioria são pequenos em comparação com outros estados, isso indica que o consumo do estado não possui altas variâncias. Entre os anos de 2004 a 2014 a série apresentou uma tendência de crescimento.

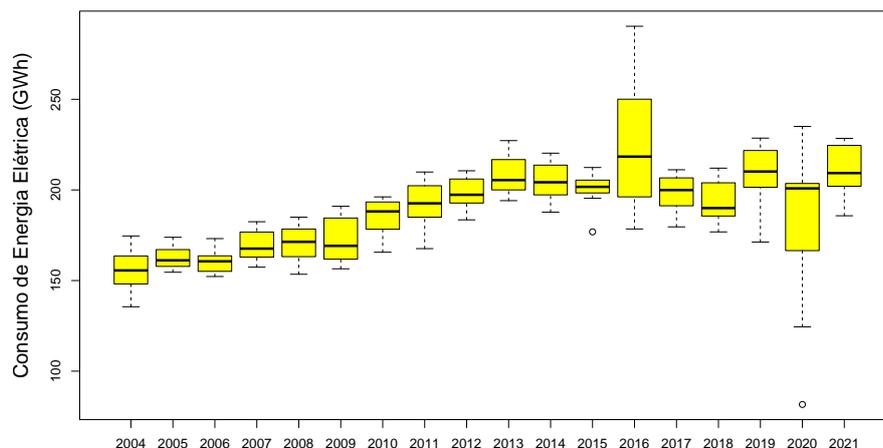


Figura 5.23 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Ceará.

Fonte: Autor (2022)

O setor industrial do Maranhão possui um PIB de 14,6 bilhões de reais, equivale a 1,1% da indústria nacional e emprega cerca de 78.821 trabalhadores. O PIB do estado é o décimo primeiro menor do Brasil e contém 7,2 milhões de habitantes ocupando 12º no ranking de estados mais populosos do Brasil. Os principais setores industriais do estado são: serviços industriais de utilidade pública (31,2%); construção (26,4%); metalurgia (10,5%); celulose e papel (10,4%) e extração de minerais metálicos (8,1%) (CNI, 2022r).

Na figura 5.24 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado do Maranhão. As medianas indicam que ocorreu uma queda acentuada no consumo entre 2011 à 2016. Existe a presença de *outliers* principalmente no ano de 2005.

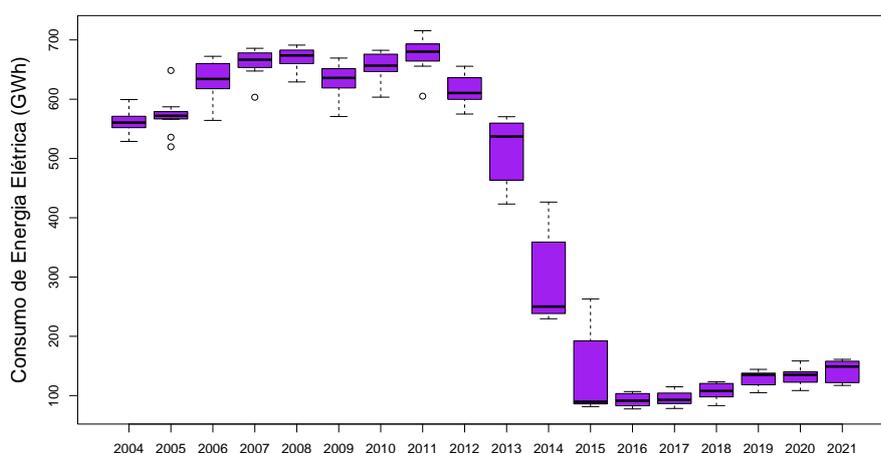


Figura 5.24 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Maranhão.

Fonte: Autor (2022)

O estado do Rio Grande do Norte possui um PIB industrial de 11,8 bilhões de reais, equivale a 0,8% da indústria brasileira. Emprega 94.168 trabalhadores na indústria e é o décimo menor PIB do Brasil, além disso, o estado possui 3,6 milhões de habitantes e é o 11º estado menos populoso do país. Os principais setores do estado são: serviços industriais de utilidade pública (27,3%); construção (22,9%); derivados de petróleo e biocombustíveis (14,3%); extração de petróleo e gás natural (13,2%) e alimentos (7,1%) (CNI, 2022x).

Na figura 5.25 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado do Rio Grande do Norte. Entre os anos de 2004 e 2007 os gráficos indicam uma tendência de crescimento.

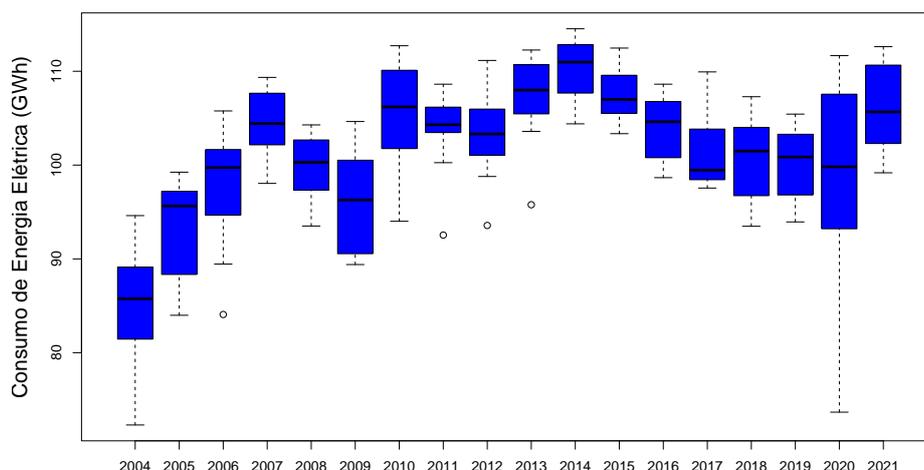


Figura 5.25 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio Grande do Norte.

Fonte: Autor (2022)

O PIB industrial do estado de Sergipe é cerca de 7,9 bilhões de reais e emprega 66.068 trabalhadores. O estado possui o quinto menor PIB do Brasil e possui 2,3 milhões de habitantes e é o 6º estado menos populoso do Brasil. Os principais setores industriais do estado são: serviços industriais de utilidade pública (42,5%); construção (19,6%); alimentos (10,1%); químicos (3,2%) e minerais não metálicos (3,0%) (CNI, 2022j).

Na figura 5.26 encontra-se o gráfico box-plot do consumo anual do setor industrial do estado do Sergipe. Os gráficos apresentam um pico no consumo entre os anos de 2012 à 2014, logo depois uma queda até o ano de 2019.

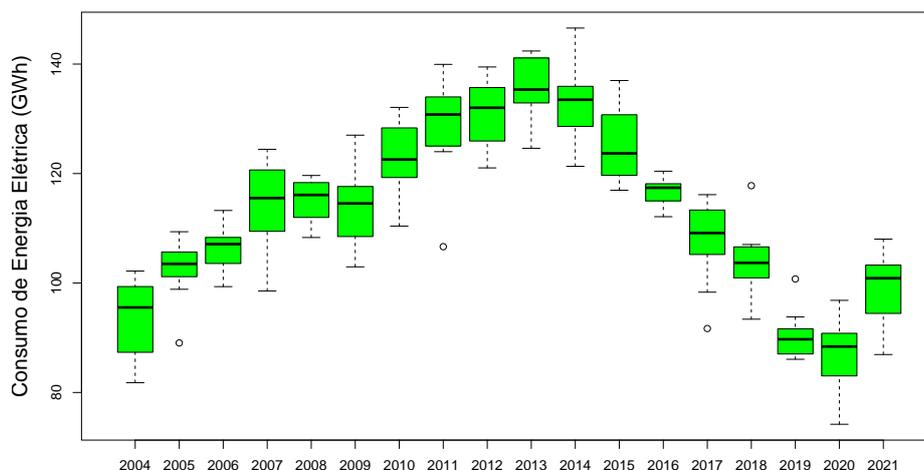


Figura 5.26 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Sergipe.

Fonte: Autor (2022)

O setor industrial do estado da Paraíba possui um PIB de 9,3 bilhões de reais e emprega 110.947 trabalhadores. A Paraíba possui o nono menor PIB do Brasil e possui 4,1 milhões de habitantes, além disso, é o 13º estado menos populosos do Brasil. Os principais setores do estado são: construção (33,1%); serviços industriais de utilidade pública (23,7%); couros e calçados (12,5%); alimentos (6,4%) e minerais não metálicos (4,7%) (CNI, 2022b).

Na figura 5.27 encontra-se o gráfico box-plot do consumo anual do setor industrial paraibano. Entre os anos de 2004 a 2010 houve um crescimento no consumo de energia elétrica, depois os gráficos não apresentam mudanças de nível abruptas.

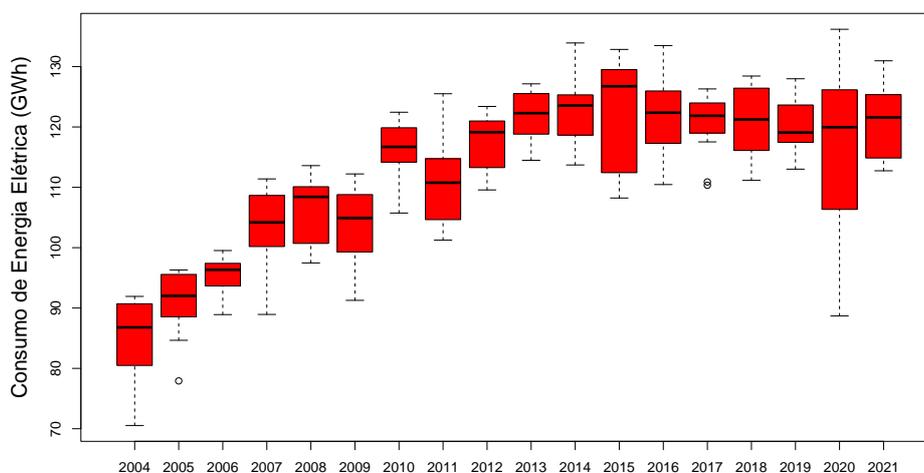


Figura 5.27 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Paraíba.

Fonte: Autor (2022)

O PIB industrial de Pernambuco é de 33,4 bilhões de reais, equivale a 2,4% da indústria nacional e emprega cerca de 273.972 trabalhadores. É o décimo maior PIB brasileiro e 9,7 milhões de pessoas habitam o estado tornando o sétimo estado mais populoso do Brasil. Os principais setores industriais do estado são: construção (19,5%); serviços industriais de utilidade pública (16,7%); alimentos (13,4%); veículos e automóveis (11,1%) e Derivados de petróleo e biocombustíveis (10%) (CNI, 2022f).

Na figura 5.28 encontra-se o gráfico box-plot do consumo anual do setor industrial pernambucano. Existe uma tendência de crescimento no consumo de energia elétrica entre os anos de 2004 a 2016.

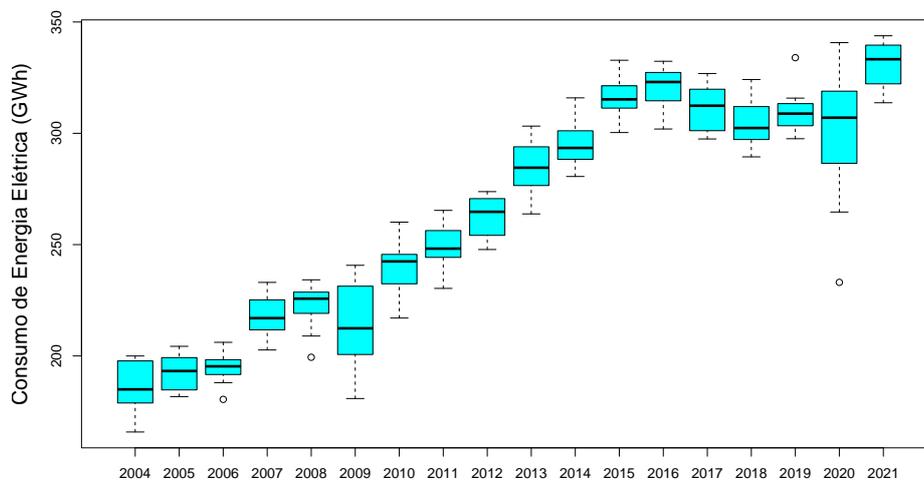


Figura 5.28 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Pernambuco.

Fonte: Autor (2022)

O setor industrial do Piauí possui um PIB industrial de 5,8 bilhões de reais, equivalente a 0,4% da indústria brasileira e empregando 51.208 trabalhadores. É o sétimo menor PIB brasileiro. Com 3,3 milhões de habitantes, é o 9º estado menos populoso do País. Os principais setores industriais do estado são: construção (44,8%); serviços industriais de utilidade pública (29,6%); alimentos (8,2%); bebidas (5,1%) e manutenção e reparação (3,1%) (CNI, 2022v)

Na figura 5.29 encontra-se o gráfico box-plot do consumo anual do setor industrial piauiense. Entre os anos de 2004 e 2013, existe uma tendência de crescimento, até atingir um pico no consumo de energia no ano de 2014.

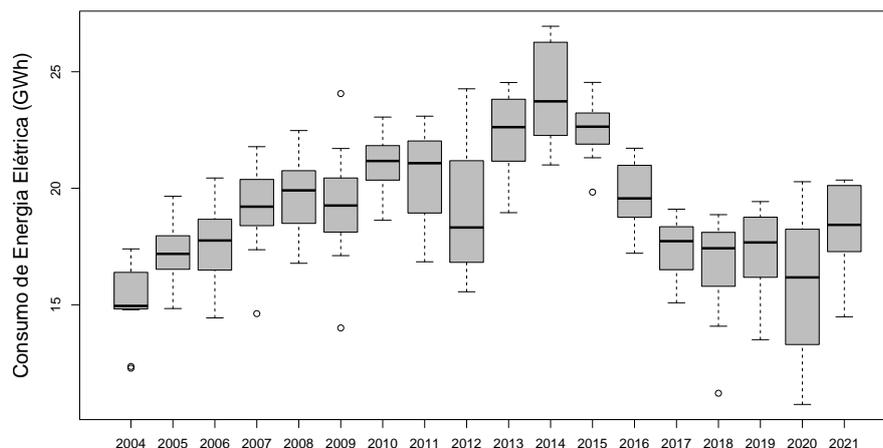


Figura 5.29 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado da Piauí.

Fonte: Autor (2022)

Observe as figuras 5.30 exibindo os gráficos da séries temporal dos dados de consumo de energia elétrica do setor industrial da região Nordeste em comparação com seus estados.

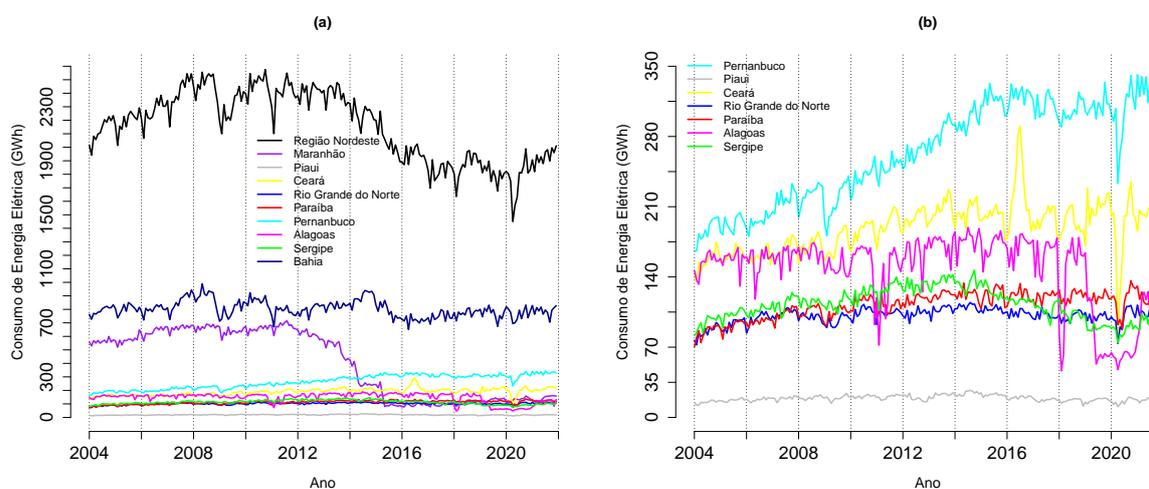


Figura 5.30 – (a) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Nordeste e seus estados. (b) Comparação entre as séries temporais de consumo de energia elétrica do setor industrial de sete estados da região Norte.

Fonte: Autor (2022)

Todas as séries temporais possuem algum tipo de sazonalidade e mudanças de nível. Algumas séries possuem tendência de crescimento, como a série do estado de Pernambuco, contudo a maioria entrega uma tendência variável. A figura 5.30 mostra que o setor industrial baiano é o que mais consumo energia elétrica e o setor industrial piauiense obteve o menor consumo. A partir de 2012, a série do estado do Maranhão possui uma tendência de queda. É perceptível nos estados de Alagoas e Ceará altas variâncias nos dados da série temporal. O estado de Sergipe obteve um aumento de consumo entre os anos 2012 a 2016.

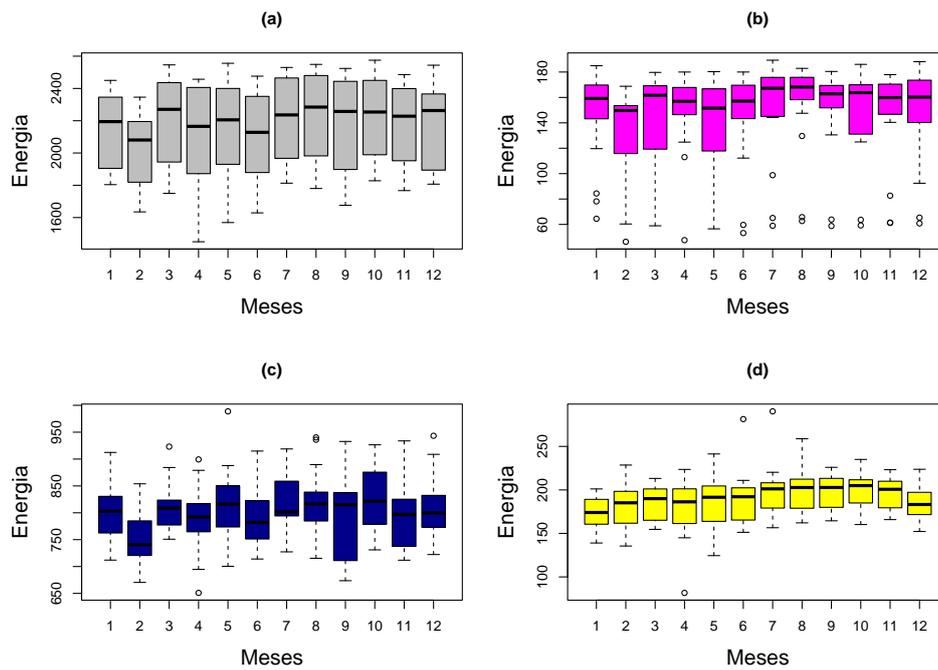


Figura 5.31 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Nordeste; (b) do Alagoas; (c) da Bahia; (d) do Ceará.

Fonte: Autor (2022)

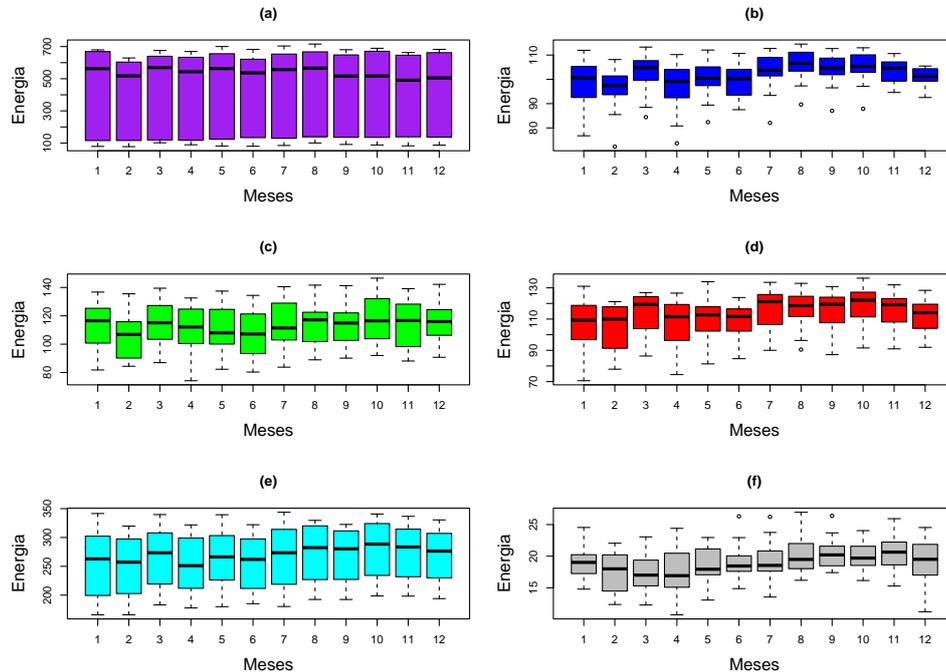


Figura 5.32 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) do Maranhão; (b) do Rio Grande do Norte; (c) do Sergipe; (d) da Paraíba; (e) de Pernambuco; (f) do Piauí.

Fonte: Autor (2022)

Nas figuras 5.31 e 5.32, observa-se o comportamento sazonal dado pelos gráficos box-plot mensais. O estado de Alagoas possui maiores índices de consumo nos meses de julho a dezembro. O mês de menor consumo é em fevereiro. Na Bahia, o setor industrial consome altas cargas de energia elétrica no mês de outubro e a redução ocorre em fevereiro.

No Ceará, o consumo de energia elétrica industrial não possui altas variações nos box-plot mensais, contudo, é visível um singelo aumento no consumo entre os meses de agosto à outubro. No estado do Maranhão o setor industrial se destaca pelas altas variações, em todos os meses, no consumo de energia elétrica. Isso se evidencia pelo tamanho do intervalo interquartil. Existe uma pequena redução no consumo nos meses de fevereiro e junho. O Rio Grande do Norte entrega muitas oscilações em seus gráficos mensais, todavia, em março e agosto os meses possuem um consumo maior e nos dois últimos meses no ano é perceptível uma decréscimo em seu consumo.

O setor industrial do Sergipe tem uma redução no consumo de energia elétrica no mês de fevereiro e junho. Na Paraíba e em Pernambuco, a alta ocorre em março e entre julho e outubro. No Piauí, os meses de fevereiro e abril entregam uma redução no consumo.

A tabela 5.13, apresenta as correlações entre os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados. A região Nordeste possui correlações consideráveis com o estado do Maranhão, Bahia e Sergipe. O estado do Maranhão possui alta correlação negativa com Pernambuco. Os estados do Ceará, Paraíba, Pernambuco e Rio Grande do Norte também entregaram correlações significativas.

Tabela 5.13 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados.

	O*	MA	PI	CE	RN	PB	PE	AL	SE	BA
O*	1.00	0.87	0.43	-0.15	0.24	-0.16	-0.52	0.54	0.67	0.68
MA	0.87	1.00	0.09	-0.50	-0.17	-0.54	-0.83	0.31	0.34	0.43
PI	0.43	0.09	1.00	0.41	0.60	0.40	0.23	0.40	0.68	0.35
CE	-0.15	-0.50	0.41	1.00	0.64	0.79	0.77	0.01	0.29	-0.06
RN	0.24	-0.17	0.60	0.64	1.00	0.75	0.57	0.17	0.57	0.33
PB	-0.16	-0.54	0.40	0.79	0.75	1.00	0.85	-0.04	0.34	0.04
PE	-0.52	-0.83	0.23	0.77	0.57	0.85	1.00	-0.21	0.07	-0.21
AL	0.54	0.31	0.40	0.01	0.17	-0.04	-0.21	1.00	0.59	0.32
SE	0.67	0.34	0.68	0.29	0.57	0.34	0.07	0.59	1.00	0.40
BA	0.68	0.43	0.35	-0.06	0.33	0.04	-0.21	0.32	0.40	1.00

*região Nordeste

5.4 Região Centro-Oeste

Nesta seção exibida uma análise exploratória de dados do consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste, estes, são: Mato Grosso, Mato Grosso do Sul, Goiás e Distrito Federal. As tabelas 5.14 e 5.15 apresentam o resumo estatístico dos dados dos estados do Centro-Oeste nos anos de 2019 e 2020. As tabela completas se encontram no anexo.

Tabela 5.14 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste em GWh para o ano de 2019.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Mato Grosso	181,07	152,95	12,37	162,50	199,03	6,83
Mato Grosso do Sul	112,63	4,71	2,17	109,41	115,80	1,93
Goiás	467,58	602,23	24,54	422,27	504,84	5,25
Distr. Federal	43,53	4,86	2,20	39,63	46,74	5,07

Tabela 5.15 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste em GWh para o ano de 2020.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Mato Grosso	190,38	234,60	15,32	162,78	212,56	8,05
Mato Grosso do Sul	121,27	55,77	7,47	105,04	131,90	6,16
Goiás	480,38	270,59	16,45	452,65	510,33	3,42
Distr. Federal	49,37	48,61	6,97	37,81	56,93	14,12

Mato Grosso possui um PIB industrial de 20,6 bilhões de reais, essa quantia é equivalente à 1,5% da indústria brasileira. O setor industrial emprega cerca de 152.854 trabalhadores e o estado possui o décimo maior PIB do Brasil e comporta 3,6 milhões de habitantes sendo assim o 12º estado menos populoso do país. Os principais setores industriais do estado são: alimentos (27,7%); construção (26,6%); serviços industriais de utilidade pública (21,5%); derivados de petróleo e biocombustíveis (6,5%) e químicos (3,8%) (CNI, 2022s).

Na figura 5.33, observa-se o gráfico box-plot do consumo de energia elétrica das indústrias mato-grossense. Existe uma tendência de crescimento ao longo do anos, apesar da queda no consumo entre os anos de 2014 e 2016.

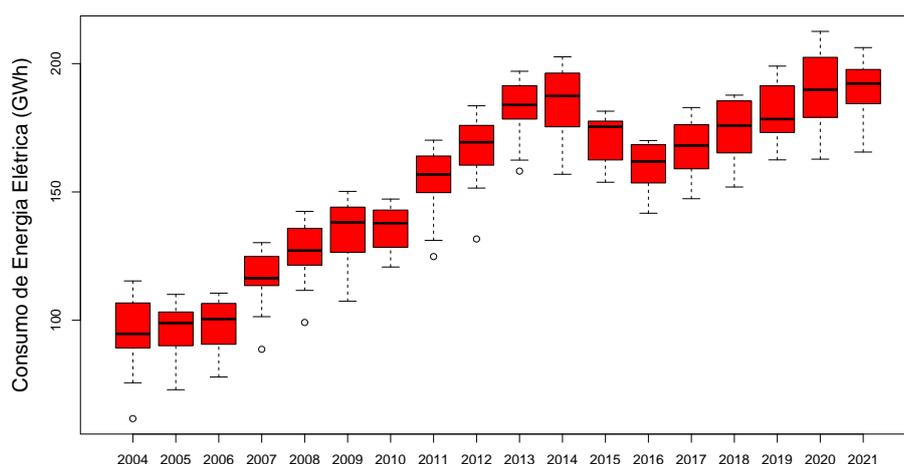


Figura 5.33 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Mato Grosso.

Fonte: Autor (2022)

O estado do Mato Grosso do Sul possui um PIB industrial de 20,5 bilhões, equivalente a 1,5% da indústria do Brasil. O setor industrial emprega 125.665 trabalhadores e 55,6% destes

estão nas indústrias de grande porte, que representam 1,5% das indústrias do estado. O PIB de Mato Grosso do Sul é o décimo terceiro menor do país e é o 7º estado menos populoso do Brasil. Os principais setores do estado são: serviços industriais de utilidade pública (26,1%); construção (20,6%); alimentos (15,7%), celulose e papel (14,7%) e derivados de petróleo e biocombustíveis (12,2%) (CNI, 2022t)

Na figura 5.34 é exibido o gráfico box-plot do consumo de energia elétrica do setor industrial do estado do Mato Grosso do Sul. As flutuações dos box-plot anuais indicam uma tendência de crescimento, entre os anos de 2013 e 2017 é visível uma queda no consumo, que é retomado nos anos subsequentes.

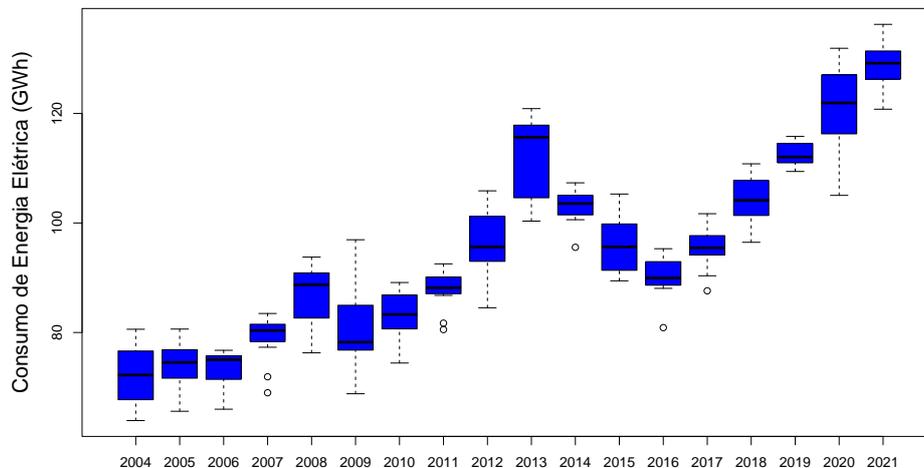


Figura 5.34 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Mato Grosso do Sul.

Fonte: Autor (2022)

O estado do Goiás possui um PIB industrial de 39,2 bilhões de reais, essa quantia equivale a 2,8% da indústria brasileira e emprega 327.195 trabalhadores. O estado possui uma população de 7,2 milhões de habitantes e é o 11º estado mais populoso do país, além disso possui o nono maior PIB entre os estados brasileiros. Os principais setores industriais do estado são: construção (25,4%); alimentos (22,9%); serviços industriais de utilidade pública (17,1%); derivados de petróleo e biocombustíveis (8,4%) e químicos (4,0%) (CNI, 2022d).

A figura 5.35 exibe o gráfico box-plot anual do consumo de energia elétrica do setor industrial do estado de Goiás. As flutuações dos box-plot indicam uma tendência de crescimento.

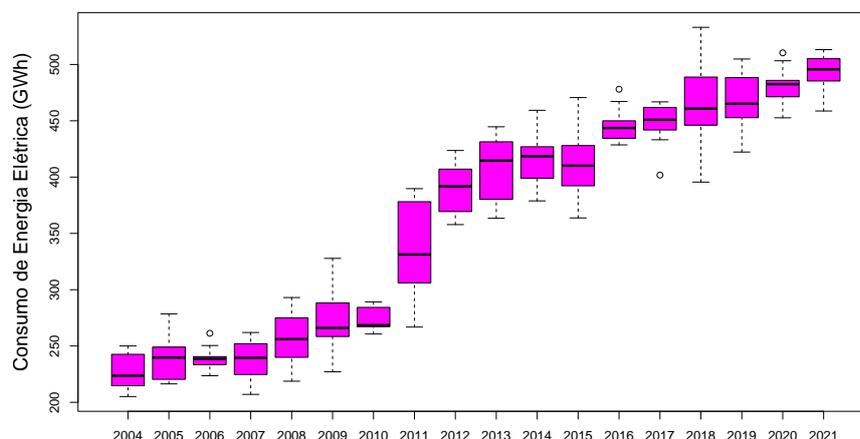


Figura 5.35 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Goiás.

Fonte: Autor (2022)

O estado do Distrito Federal possui um PIB industrial de 9,5 bilhões de reais e isso equivale a 0,7% da industrial do Brasil. O estado emprega 86.650 trabalhadores na indústria e é o 8º estado menos populoso do país, além disso, é o 8º PIB brasileiro. Os principais setores industriais do estado são: construção (51,2%); serviços industriais de utilidade pública (24,6%); alimentos (6,4%); bebidas (4,7%) e minerais não metálicos (2,9%) (CNI, 2022p).

A figura 5.36 exibe o gráfico box-plot anual do consumo de energia elétrica do setor industrial do estado do Distrito Federal. As flutuações dos box-plot indicam o mesmo observado na média anual dos dados, existe uma tendência de crescimento até 2014 depois uma queda no consumo.

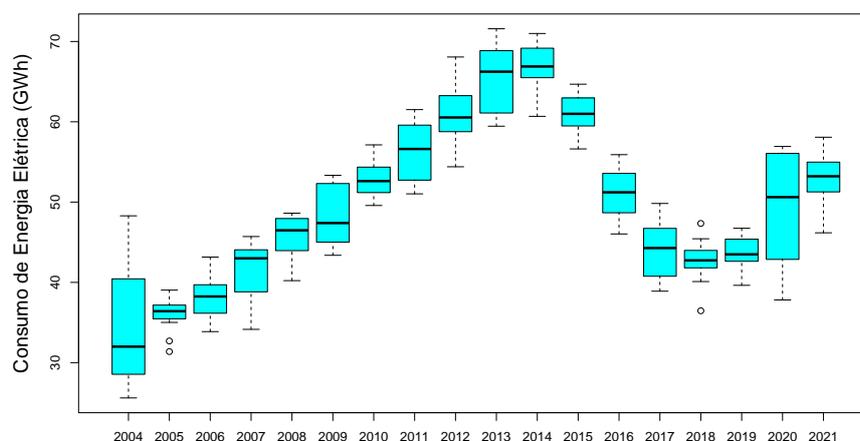


Figura 5.36 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Distrito Federal.

Fonte: Autor (2022)

Na figura 5.37 são exibidos os gráficos de séries temporais dos dados de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus respectivos estados.

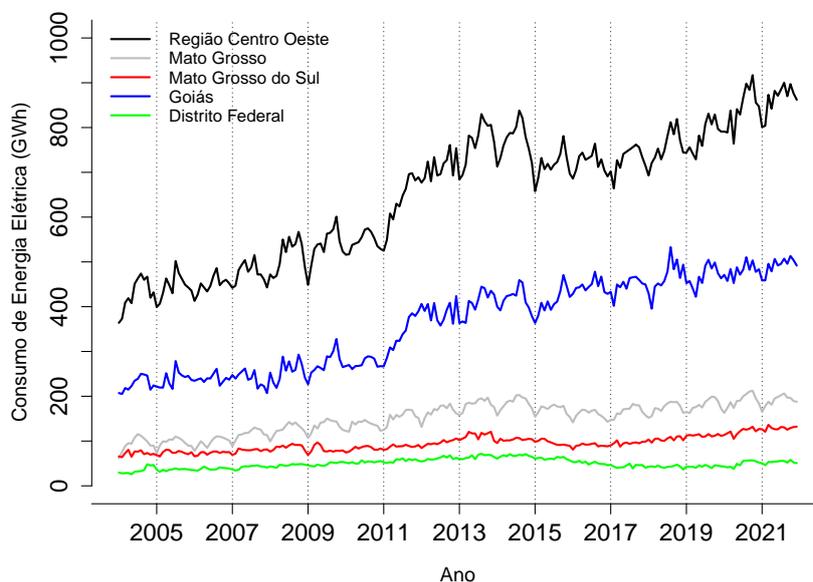


Figura 5.37 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus estados.

Fonte: Autor (2022)

As séries temporais expostas da figura 5.37 possuem alguma sazonalidade e tendência. As indústrias goianas são as que mais consomem energia elétrica, em contrapartida, o Distrito Federal é a que menos consome. A sazonalidade pode ser observado ao observar os gráficos box-plot com dados separados por mês. Veja a figura 5.38 que contém os gráficos box-plot mensal do consumo de energia elétrica do setor industrial da região Centro-Oeste seus estados.

No estado de Goiás é perceptível que no mês de janeiro o consumo diminui e isso também acontece em junho e julho. No mês de agosto, setembro e outubro ocorre um aumento. Já no Mato Grosso é visível que entre os meses de julho a setembro ocorre um aumento no consumo e uma arrefecida no fim de ano, o mês de menor consumo é em janeiro.

O setor industrial do Mato Grosso do Sul possui seu menor consumo em janeiro e logo depois ocorre um aumento no consumo e a partir disso os gráficos não exibem muitas flutuações nos box-plot. O Distrito Federal possui um aumento entre agosto e novembro.

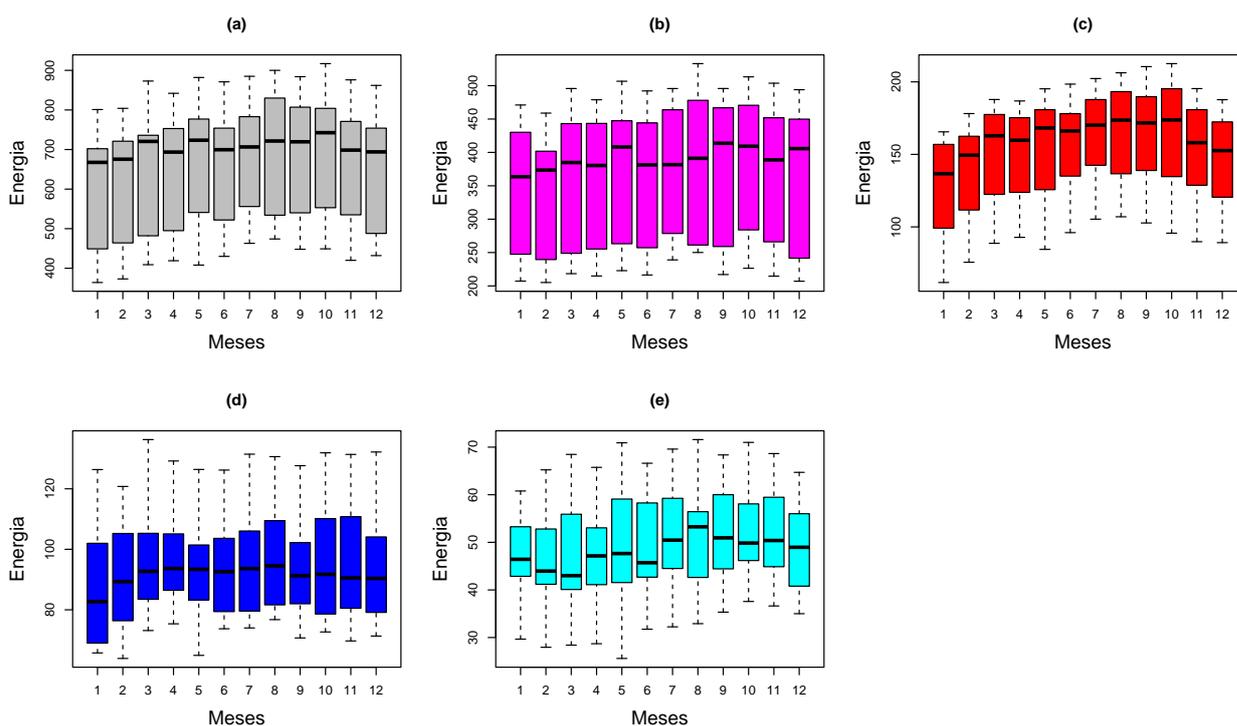


Figura 5.38 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Centro-Oeste; (b) de Goiás; (c) do Mato Grosso; (d) do Mato Grosso do Sul; (e) do Distrito Federal.

Fonte: Autor (2022)

A tabela 5.16 apresenta as correlações entre os dados de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus estados, a tabela de maneira numérica e a figura utilizando gráfico de dispersão. Os estados de Mato Grosso, Mato Grosso do Sul e Goiás possui correlações altas entre eles. No Distrito Federal as correlações com os outros estados são consideráveis, todavia, são baixas em comparação a correlação entre os outros estados.

Tabela 5.16 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Centro-Oeste e seus estados.

	Centro-Oeste	Mato G. do Sul	Mato Grosso	Goiás	Distrito Federal
Centro-Oeste	1.00	0.91	0.96	0.97	0.58
Mato Gr. do Sul	0.91	1.00	0.88	0.84	0.46
Mato Grosso	0.96	0.88	1.00	0.90	0.65
Goiás	0.97	0.84	0.90	1.00	0.44
Distrito Federal	0.58	0.46	0.65	0.44	1.00

5.5 Região Sudeste

Nesta seção será exibida uma análise exploratória de dados de consumo de energia elétrica do setor industrial dos estados da região Sudeste. Os estados que compõe esta região são: São Paulo, Minas Gerais, Espírito Santo e Rio de Janeiro. As tabelas 5.17 e 5.18 apresentam o resumo estatístico dos dados dos estados do Sudeste nos anos de 2019 e 2020. As tabela completas se encontram no anexo.

Tabela 5.17 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sudeste em GWh para o ano de 2019.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
São Paulo	3969,64	8271,74	90,95	3811,38	4138,19	2,29
Minas Gerais	2480,80	6269,91	79,18	2353,20	2624,62	3,19
Espírito Santo	333,93	444,87	21,09	288,68	351,61	6,32
Rio de Janeiro	667,37	769,46	27,74	613,78	703,19	4,16

Tabela 5.18 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sudeste em GWh para o ano de 2020.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
São Paulo	3830,02	152801,93	390,90	3104,15	4277,90	10,21
Minas Gerais	2501,89	22598,28	150,33	2268,05	2728,95	6,01
Espírito Santo	314,48	717,23	26,78	273,72	349,66	8,52
Rio de Janeiro	670,03	2771,28	52,64	564,96	722,37	7,86

O setor industrial do estado de São Paulo tem um PIB de 400,9 bilhões de reais, esta quantia é equivalente a 28,9% da indústria brasileira e emprega 2.899.944 trabalhadores da indústria. É o estado mais populoso do país com 46,6 milhões de habitantes e possui o maior PIB do país, cerca de 2 trilhões de reais. Os principais setores do estado são: construção (16,7%); derivados do petróleo e biocombustíveis (11,4%); alimentos (9,3%); serviços industriais de utilidade pública (8,9%); químicos (8,3%) (CNI, 2022k).

Na figura 5.39 observa-se os gráficos box-plot anual dos dados de consumo de energia elétrica do setor industrial paulista. Existe alguns *outliers* e a presença da tendência de crescimento, através das flutuações dos box-plot, de 2004 à 2011, logo depois uma queda até 2016 e uma retomada do consumo até 2021.

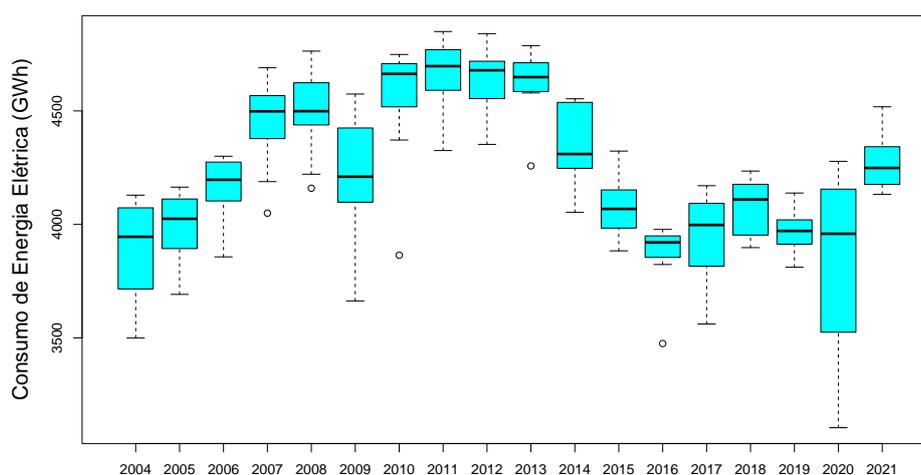


Figura 5.39 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de São Paulo.

Fonte: Autor (2022)

O setor industrial do estado de Minas Gerais possui um PIB de 154,8 bilhões de reais, equivalente a 11,2% da indústria brasileira, empregando 1.148.179 trabalhadores. O estado possui o terceiro maior PIB do Brasil e com 21,4 milhões de habitantes é o segundo estado mais populoso do país. Os principais setores industriais do estado mineiro são: construção (14,8%); extração de minerais metálicos (16,0%); serviços industriais de utilidade pública (12,2%); metalurgia (11,5%) e alimentos (11,4%) (CNI, 2022e).

A figura 5.40 estão os gráficos box-plot anuais dos dados dados de consumo de energia elétrica do setor industrial mineiro. As flutuações dos gráficos entregam muitas mudanças de nível então, neste estado tem-se uma tendência variante. Os anos 2008, 2009 e 2020 tiveram altas variâncias. Existe poucos *outliers* e entre os anos de 2016 à 2021 as flutuações indicam que, recentemente, o setor industrial vem aumentando seu consumo de energia elétrica.

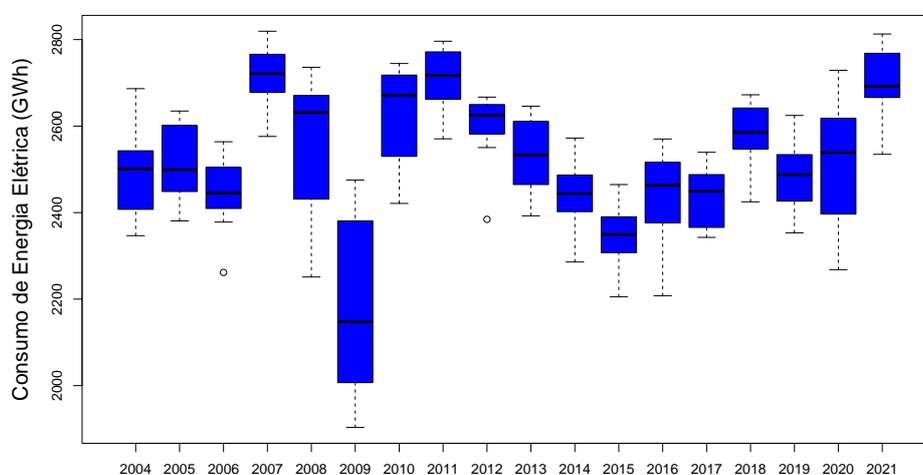


Figura 5.40 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Minas Gerais.

Fonte: Autor (2022)

O setor industrial do estado do Espírito Santo possui um PIB de 30,5 bilhões, equivalente a 2,2% da indústria brasileira, empregando 180.446 trabalhadores. O estado possui o décimo quarto estado mais populosos do país com 4,1 milhões de habitantes. Os principais setores industriais do estado capixaba são: construção (17,1%); extração de minerais metálicos (10,2%); serviços industriais de utilidade pública (9,6%); metalurgia (8,1%) e minerais não metálicos (6,3%) (CNI, 2022q).

Na figura 5.41 os gráficos box-plot exibem entre os anos de 2004 a 2015, apesar do revês em 2009, uma tendência de crescimento, logo depois uma que abrupta no consumo em 2016 e baixas flutuações dos box-plot até 2021.

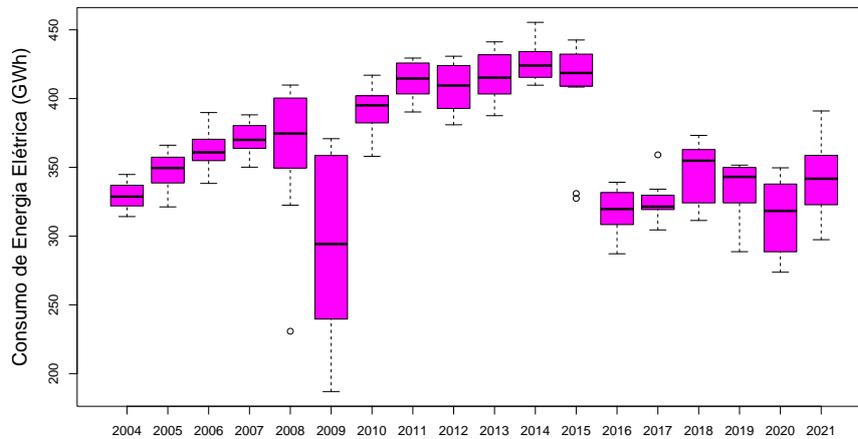


Figura 5.41 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Espírito Santo.

Fonte: Autor (2022)

O setor industrial do Rio de Janeiro possui um PIB de 165,8 bilhões de reais, equivalente a 12,0% da indústria brasileira e empregando 545.494 trabalhadores. O estado possui o segundo maior PIB do Brasil e é o terceiro estado mais populoso do país com 17,5 milhões de habitantes. Os principais setores industriais do estado carioca são: extração de petróleo e gás natural (46,3%); construção (13,2%); serviços industriais de utilidade pública (11,5%); derivados de petróleo e biocombustíveis (11,2%) e atividades de apoio à extração de minerais (5,6%) (CNI, 2022w).

A figura 5.42 apresenta os gráficos box-plot de cada ano dos dados de consumo de energia elétrica do setor industrial carioca. Existe mudanças de nível na série temporal. Entre os anos de 2012 à 2020 foi visto uma tendência decrescente.

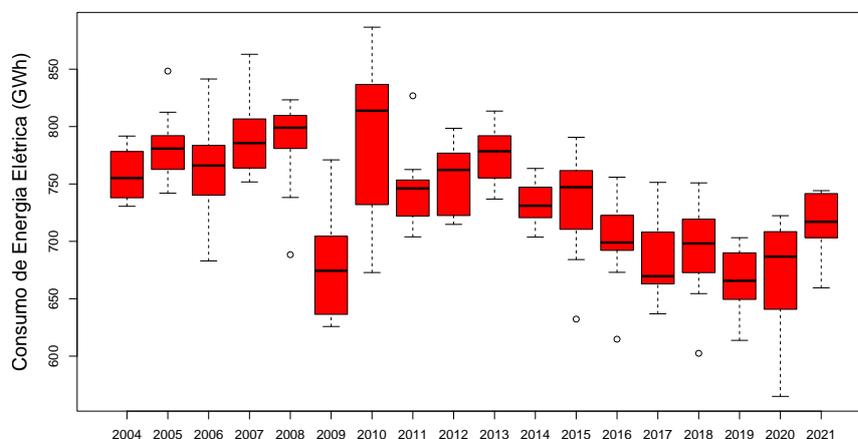


Figura 5.42 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio de Janeiro.

Fonte: Autor (2022)

Na figura 5.43 são exibidos os gráficos de séries temporais dos dados de consumo de energia elétrica do setor industrial da região Sudeste e seus respectivos estados. As indústrias de São Paulo são as que consomem mais energia elétrica, seguida por Minas Gerais, Rio de Janeiro e Espírito Santo. As séries temporais possuem sazonalidade e algumas mudanças de nível. A série de São Paulo, por ter alto consumo, possui um comportamento similar a série da região Sudeste.

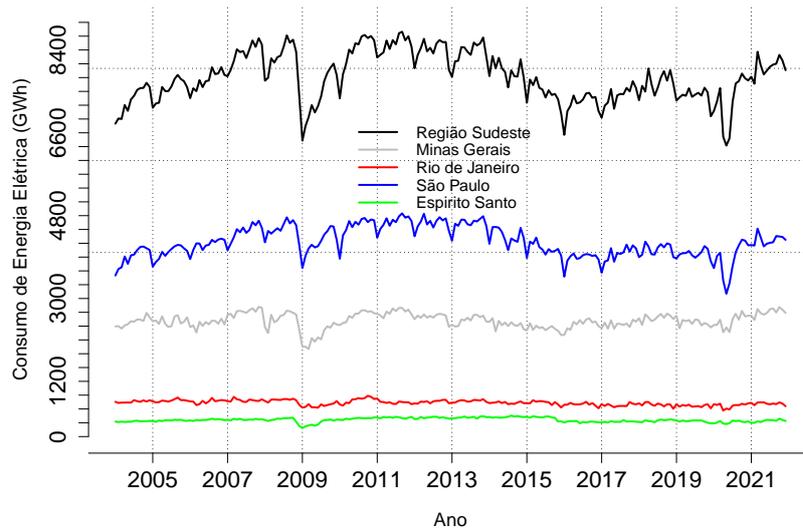


Figura 5.43 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Sudeste e seus estados.

Fonte: Autor (2022)

Veja a figura 5.44 que contém os gráficos box-plot mensal do consumo de energia elétrica do setor industrial da região Sudeste e seus estados. Em São Paulo as indústrias consomem menos energia elétrica no mês de janeiro, depois é visível o crescimento do consumo até o mês de maio, doravante, uma arrefecida até o mês de julho e, novamente, o crescimento do consumo nos meses subsequentes.

Os gráficos box-plot do setor industrial mineiro exibem nos primeiros três meses do ano poucas flutuações, ou seja, são meses que possuem consumo numericamente próximos. Ocorre um crescimento no mês de abril até dezembro, apesar do mês de maio entregar uma leve queda. No estado do Espírito Santo, as indústrias consomem mais energia elétrica nos meses de março e agosto, como entregam as flutuações dos gráficos box-plot. Entre os meses de julho a setembro, ocorre um aumento no consumo, logo depois uma arrefecida até o final do ano. No Rio de Janeiro, as indústrias consomem menos energia elétrica no mês de fevereiro, depois ocorre um crescimento onde os gráficos entregam poucas flutuações até o mês de maio. Em junho ocorre uma queda e depois uma retomada até o final do ano, sendo o mês de agosto obtendo os maiores consumos, todavia, em outubro é visível um *outlier* indicando que em algum momento entre 2004 a 2021 ocorreu o maior consumo entre os dados analisados.

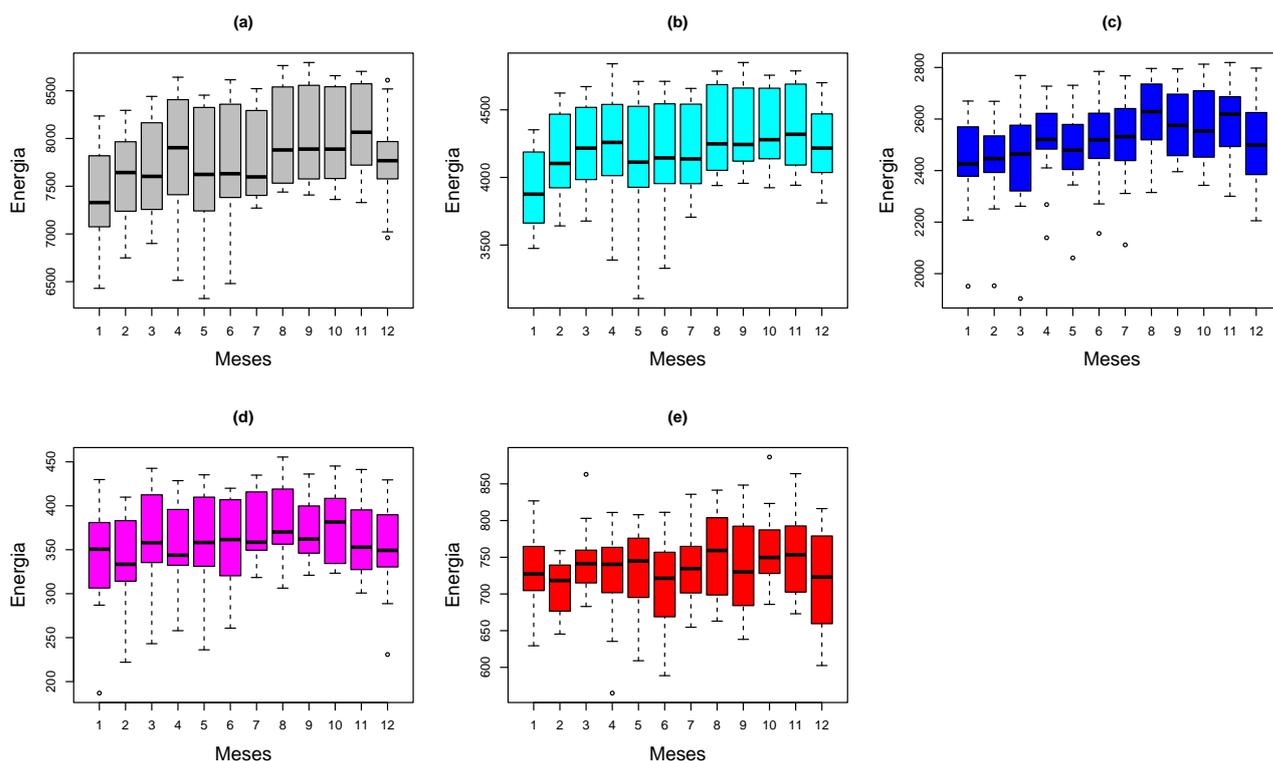


Figura 5.44 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Sudeste; (b) de São Paulo; (c) de Minas Gerais; (d) do Espírito Santo; (e) do Rio de Janeiro.

Fonte: Autor (2022)

Na tabela 5.19 estão os valores das correlações entre os dados de consumo de energia elétrica do setor industrial da região Sudeste e seus estados. São Paulo tem alta correlação com a região Sudeste, indicando que é um estado muito importante para esta região. A correlação da região Sudeste com o Rio de Janeiro é alta, todavia é a mais baixa em comparação com os outros estados. A maior correlação entre os estados é de São Paulo com o Espírito Santo.

Tabela 5.19 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Sudeste e seus estados.

	Sudeste	Minas Gerais	Espírito Santo	Rio de Janeiro	São Paulo
Sudeste	1,00	0,74	0,71	0,63	0,95
Minas Gerais	0,74	1,00	0,43	0,47	0,54
Espírito Santo	0,71	0,43	1,00	0,54	0,65
Rio de Janeiro	0,63	0,47	0,54	1,00	0,56
São Paulo	0,95	0,54	0,65	0,56	1,00

5.6 Região Sul

Nesta seção será exibida uma análise exploratória de dados de consumo de energia elétrica do setor industrial dos estados da região Sul. Os estados que compõe esta região são: Paraná, Santa Catarina e Rio Grande do Sul. As tabelas 5.20 e 5.21 apresentam o resumo es-

tatístico dos dados dos estados do Sudeste nos anos de 2019 e 2020. As tabelas completas se encontram no anexo.

Tabela 5.20 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sul em GWh para o ano de 2019.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Paraná	1073,58	1032,62	32,13	1024,38	1121,06	2,99
Santa Catarina	884,49	1302,97	36,10	812,40	933,19	4,08
Rio Gr. do Sul	813,88	987,78	31,43	744,67	848,97	3,86

Tabela 5.21 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial dos estados da região Sul em GWh para o ano de 2020.

Estados	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
Paraná	1067,94	5921,85	76,95	919,66	1169,53	7,21
Santa Catarina	882,11	7688,11	87,68	728,48	992,38	9,94
Rio Gr. do Sul	783,11	4987,45	70,62	661,81	877,89	9,02

O setor industrial do estado do Paraná possui um PIB de 105,8 bilhões de reais, esta quantia é equivalente a 7,6% da indústria do Brasil empregando 814.731 trabalhadores. O Paraná possui o quinto maior PIB do Brasil e o quinto estado mais populoso com 11,6 milhões de habitantes. Os principais setores do estado são: serviços industriais de utilidade pública (19,3%); alimentos (18,6%); construção (16,2%); veículos automotores (8,2%) e derivados de petróleo e biocombustíveis (7,0%) (CNI, 2022u).

Na figura 5.45 é exibido os gráficos box-plot anuais do consumo de energia elétrica do setor industrial do estado do Paraná. Através das flutuações dos box-plot, é perceptível a tendência de crescimento no consumo de energia elétrica no Paraná, além disso, existe a presença de *outliers* principalmente em 2016.

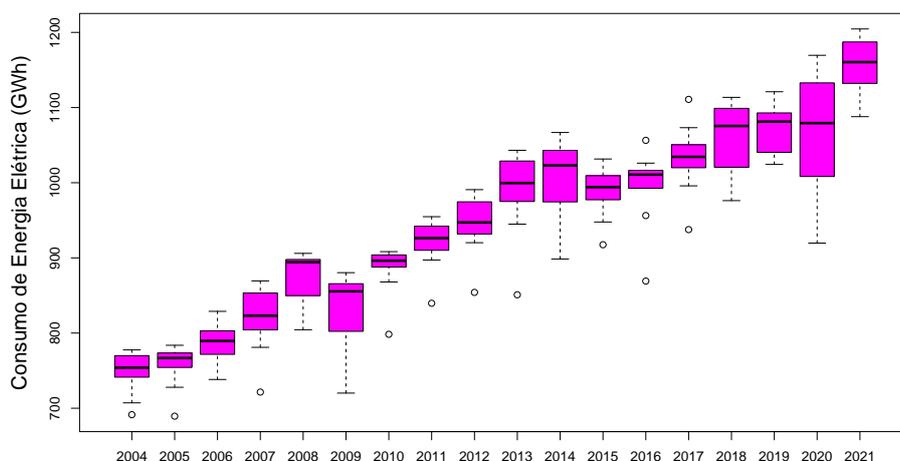


Figura 5.45 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Paraná.

Fonte: Autor (2022)

O setor industrial do estado de Santa Catarina possui um PIB de 71,2 bilhões de reais, equivalente a 5,1% da indústria brasileira e emprega 804.362 trabalhadores. Santa Catarina possui o sexto maior PIB do Brasil e o décimo estado mais populoso com 7,3 milhões de habitantes. Os principais setores do estado são: construção (17,1%); alimentos (15,5%); serviços industriais de utilidade pública (7,9%); vestuário (7,3%) e máquinas e materiais elétricos (5,7%). Estes setores, juntos, representam 53,5% da indústria do estado (CNI, 2022i)

Na figura 5.46 é exibido os gráficos box-plot anuais do consumo de energia elétrica do setor industrial do estado de Santa Catarina. Através das flutuações dos box-plot, é visível a tendência de crescimento no consumo de energia elétrica.

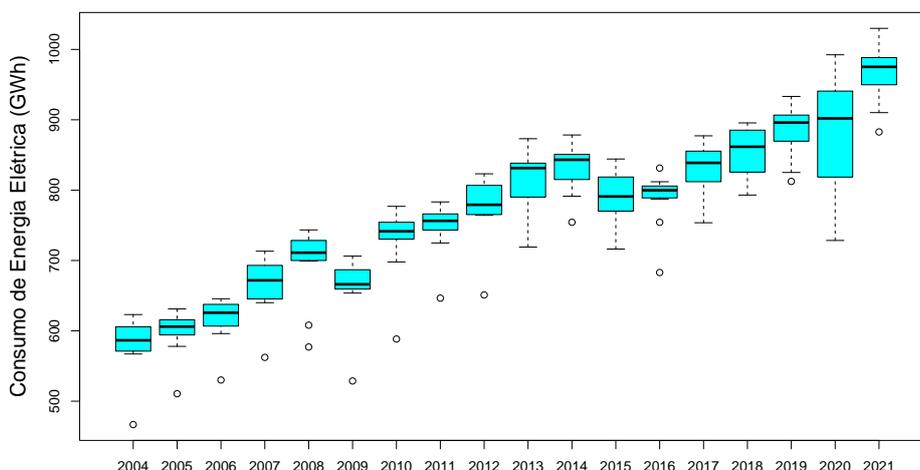


Figura 5.46 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado de Santa Catarina.

Fonte: Autor (2022)

O setor industrial do estado do Rio Grande do Sul possui um PIB de 94,6 bilhões de reais, equivalente a 6,8% da indústria do Brasil empregando 752.339 trabalhadores. O estado gaúcho possui o quarto maior PIB do Brasil e o sexto estado mais populoso com 11,5 milhões de habitantes. Os principais setores do estado são: construção (18,3%); alimentos (15,5%); serviços industriais de utilidade pública (11,3%); máquinas e equipamentos (7,0%) e químicos (6,0%) (CNI, 2022y).

Na figura 5.47 é exibido os gráficos box-plot anuais do consumo de energia elétrica do setor industrial do estado de Rio Grande do Sul. Entre os anos de 2004 à 2011 é visível uma tendência de crescimento, logo depois, uma queda.

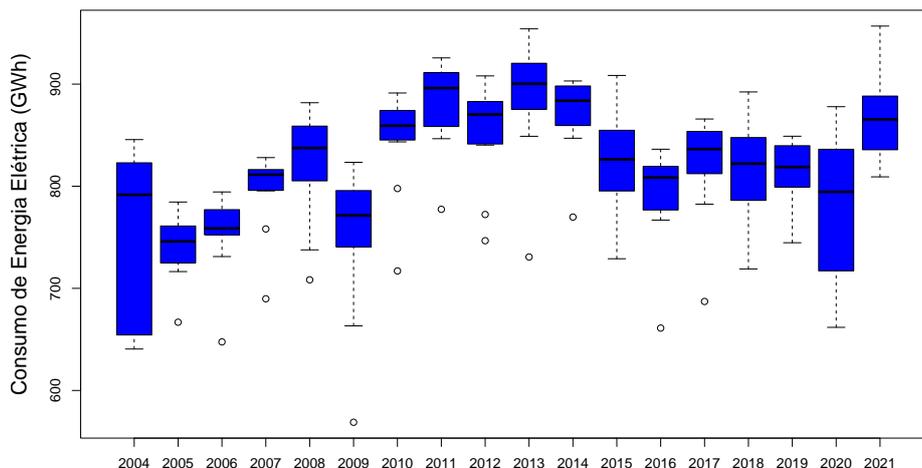


Figura 5.47 – Box-plot dos dados do consumo de energia elétrica do setor industrial do estado do Rio Grande do Sul.

Fonte: Autor (2022)

Na figura 5.48 são exibidos os gráficos de séries temporais dos dados de consumo de energia elétrica do setor industrial da região Sul e seus respectivos estados: Rio Grande do Sul, Paraná e Santa Catarina. As indústrias do Paraná passaram a ser o maior consumidor de energia elétrica da região a partir de 2008. As indústrias de Santa Catarina só ocuparam a segunda posição em consumo depois de 2018. As séries temporais possuem sazonalidade e algumas mudanças de nível.

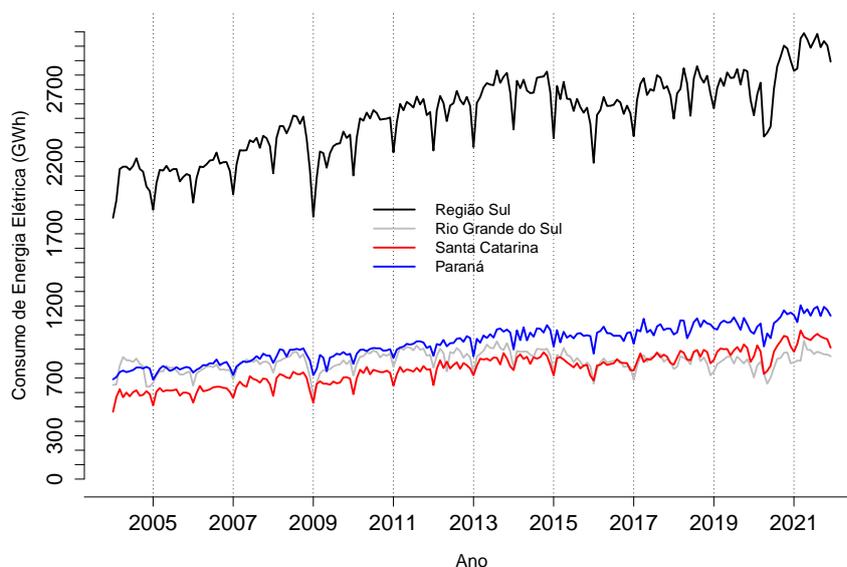


Figura 5.48 – Comparação entre as séries temporais de consumo de energia elétrica do setor industrial da região Sul e seus estados.

Fonte: Autor (2022)

Veja a figura 5.49 que contém os gráficos box-plot mensal do consumo de energia elétrica do setor industrial da região Sul seus estados. No mês de janeiro, em todos os estados, é apresentado uma redução no consumo de energia elétrica, o mesmo ocorre em dezembro.

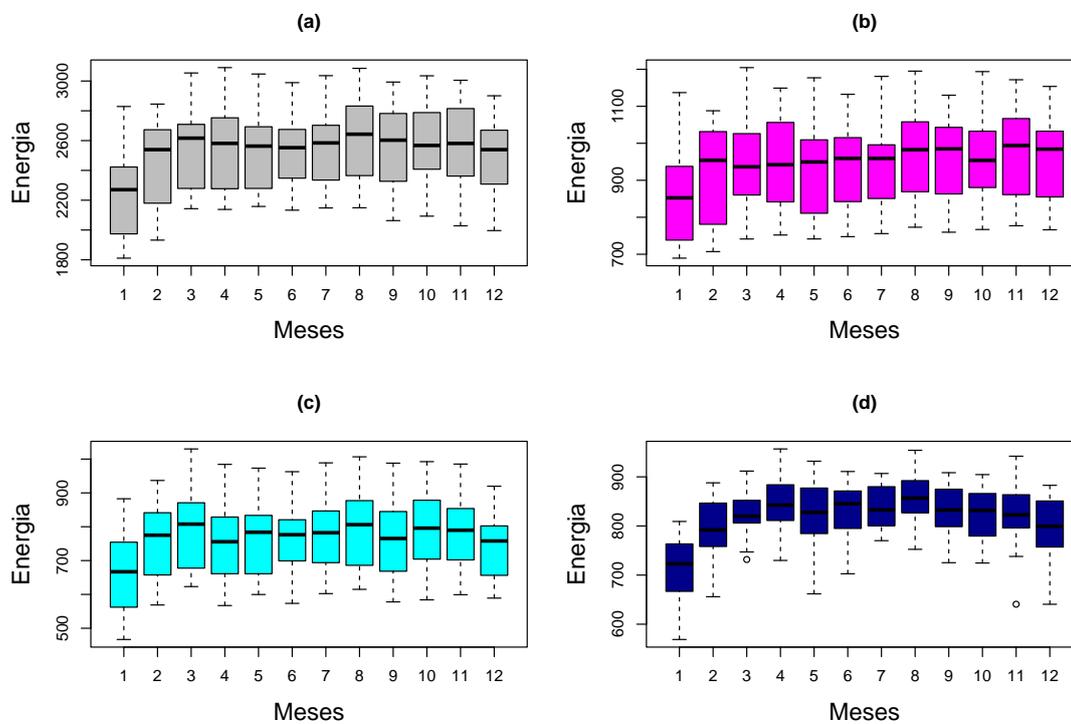


Figura 5.49 – Box-plot dos dados mensais do consumo de energia elétrica do setor industrial: (a) da região Sul; (b) do Paraná; (c) de Santa Catarina; (d) do Rio Grande do Sul.

Fonte: Autor (2022)

A tabela 5.22 exibe a correlação entre os estados e a região Sul. Os estados da região sul possuem uma correlação forte, em particular, os estado de Santa Catarina e Paraná.

Tabela 5.22 – Tabela contendo o nível de correlação entre os dados de consumo de energia elétrica do setor industrial da região Sul e seus estados.

	Região Sul	Paraná	Santa Catarina	Rio Gr. do Sul
Região Sul	1,00	0,96	0,97	0,72
Paraná	0,96	1,00	0,96	0,53
Santa Catarina	0,97	0,96	1,00	0,58
Rio Grande do Sul	0,72	0,53	0,58	1,00

Resultados e Discussões

6.1 Modelos de Suavização Exponencial

Nesta seção, serão apresentados os resultados através das abordagens adotadas via os modelos de previsão considerados. Primeiramente, será apresentado os resultados obtidos através do modelo de suavização exponencial e, em seguida, pelo modelo de Box e Jenkins.

Na tabela 6.1, está exposto o modelo de suavização exponencial utilizado em cada série regional e a nacional. Observe que existe algumas mudanças no método de suavização exponencial quando altera-se o conjunto teste, em geral, isso acontece pelas mudanças de nível que em algumas ocasiões são abruptas, com isso, com o acoplamento de novas observações, advêm novos comportamentos na série e, assim, apresentando novas interpretações de modelo. Um destaque interessante é a região Centro-Oeste, apresentou o mesmo modelo ajustado para os cinco cenários avaliados, isso se deve que a partir de 2016 a série temporal possui um comportamento de tendência sem alterações bruscas de nível.

Tabela 6.1 – Tabela contendo o tipo de modelo de suavização exponencial das séries de nível Brasil e regionais.

Teste	2017	2018	2019	2020	2021
Brasil	(A,A)	(A_d ,A)	(A_d ,A)	(A_d ,A)	(A_d ,A)
Norte	(A_d ,M)				
Nordeste	(A_d ,M)	(A_d ,M)	(A,A)	(A_d ,A)	(A_d ,A)
Centro-Oeste	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Sudeste	(A,A)	(A,A)	(A,A)	(A_d ,A)	(A_d ,A)
Sul	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

Na tabela 6.2, tem-se os valores das métricas MAPE e RMSE para a previsão utilizando os modelos suavização indicados na tabela 6.1. Veja que o modelo indicado para a região Centro-Oeste obteve bons ajustes em comparação com as outras regiões e com a série nacional já que apresentou as menores métricas em média. O pior MAPE médio foi visto na região Norte, contudo, o maior RMSE médio foi observado nas previsões nacionais. As previsões dos modelos de suavização exponencial entregaram resultados satisfatórios para as séries analisadas na tabela 6.2.

Tabela 6.2 – Tabela contendo as métricas MAPE e RMSE dos modelos suavização exponencial dos dados Nacionais e Regionais

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,85%	426,19	1,46%	258,89	2,27%	364,55
Norte	2,61%	37,61	17,07%	202,19	8,19%	118,89
Nordeste	3,90%	80,23	2,67%	59,40	5,59%	117,57
Centro-Oeste	1,80%	16,33	2,05%	19,91	2,26%	21,31
Sudeste	3,86%	311,50	1,48%	143,53	5,23%	438,75
Sul	4,23%	118,02	1,93%	80,96	1,62%	57,91
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	6,39%	936,34	3,03%	503,97	3,20%	497,99
Norte	4,35%	62,05	4,78%	70,18	7,40%	98,18
Nordeste	6,56%	135,72	5,75%	114,29	4,89%	101,44
Centro-Oeste	3,69%	34,84	2,21%	22,12	2,40%	22,90
Sudeste	7,70%	572,67	3,22%	309,39	4,30%	355,17
Sul	6,58%	215,92	1,65%	63,41	3,20%	107,24

Na tabela 6.3, observa-se o tipo de modelo de suavização exponencial utilizados para prever dados de consumo de energia elétrica do setor industrial dos estados da região Norte. Veja que em algumas séries temporais, o melhor modelo de suavização exponencial não considerou tendência nem sazonalidade, que é o exemplo da série de Rondônia nos primeiros três cenários de conjunto teste e os estados do Acre e do Amapá, que em nenhum momento foi considerado este componente. No Amazonas, somente no primeiro cenário, foi considerado a sazonalidade multiplicativa e não foi considerado tendência, contudo, nos três subsequentes a tendência considerado foi utilizando amortecimento.

Tabela 6.3 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Norte.

Teste	2017	2018	2019	2020	2021
Acre	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Amapá	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Amazonas	(N,M)	(A _d ,A)	(A _d ,A)	(A _d ,A)	(A,A)
Pará	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Rondônia	(N,N)	(N,N)	(N,N)	(A _d ,A)	(A _d ,A)
Roraima	(A _d ,A)	(A _d ,A)	(N,A)	(A,A)	(A _d ,A)
Tocantins	(N,A)	(N,A)	(A,A)	(A,A)	(N,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

Na tabela 6.4, observa-se as métricas do tipo de modelo de suavização exponencial utilizados para prever o consumo de energia elétrica do setor industrial dos estados da região Norte. O consumo de energia elétrica do estado do Amazonas apresentou o menor MAPE médio, em contrapartida, o estado do Amapá foi o maior. O estado de Roraima obteve um RMSE médio muito baixo, contudo, apresentou o segundo maior MAPE médio, isso se deve ao fato de que as métricas possuem formas diferentes de estudar o erro preditivo. O maior RMSE médio foi encontrado no estado do Pará.

Tabela 6.4 – Tabela contendo as métricas MAPE e RMSE dos modelos de suavização exponencial das séries dos estados da região Norte

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Acre	10,66%	42,07	10,96%	0,381	9,66%	0,349
Amapá	27,36%	1,89	12,96%	1,35	7,67%	0,851
Amazonas	4,85%	9,22	4,57%	7,38	3,88%	6,82
Pará	2,68%	33,74	23,33%	222,07	8,41%	99,84
Rondônia	6,61%	2,66	4,66%	2,15	2,86%	1,28
Roraima	10,59%	0,253	14,81%	0,459	27,48%	0,537
Tocantins	11,00%	3,52	8,79%	2,82	13,22%	4,06
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Acre	5,04%	0,217	7,49%	0,354	8,76%	8,67
Amapá	1,15%	1,35	27,07%	2,75	15,24%	1,64
Amazonas	1,11%	18,25	5,19%	8,50	3,92%	10,03
Pará	5,63%	67,43	3,84%	47,79	8,78%	94,17
Rondônia	7,03%	3,43	9,55%	4,29	6,14%	2,76
Roraima	13,58%	0,299	5,74%	0,12	14,44%	0,33
Tocantins	7,60%	2,41	11,78%	4,32	10,48%	3,43

Na tabela 6.5, pode-se observar o tipo de modelo de suavização exponencial utilizado para prever o consumo de energia elétrica do setor industrial dos estados da região Nordeste. Nos estados do Ceará, Alagoas, Bahia e Piauí o modelo selecionado em todos os cenários não considera tendência, já no Rio Grande do Norte, a modelagem de tendência foi aditiva com *damped*. Na maioria dos casos, o modelo com sazonalidade aditiva foi considerado, somente no primeiro cenário, no estado do Ceará, que foi utilizado a modelagem de sazonalidade multiplicativa.

Tabela 6.5 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Nordeste.

Teste	2017	2018	2019	2020	2021
Alagoas	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Bahia	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Ceará	(N,M)	(N,A)	(N,A)	(N,A)	(N,A)
Maranhão	(A,A)	(A _d ,A)	(A _d ,A)	(A _d ,A)	(A _d ,A)
Paraíba	(A _d ,A)	(A _d ,A)	(A _d ,A)	(A _d ,A)	(A,A)
Pernambuco	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Piauí	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Rio G. do Norte	(A _d ,A)				
Sergipe	(A _d ,A)	(A _d ,A)	(A _d ,A)	(A,A)	(A _d ,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

A tabela 6.6 mostra as métricas para cada modelo de suavização exponencial utilizado para prever o consumo de energia elétrica do setor industrial na região Nordeste. Os modelos obtidos para os estados do Rio Grande do Norte, Bahia e Pernambuco apresentaram valores de MAPE médios baixos, indicando que o modelo selecionado foi interessante. Em contrapartida,

o estado do Alagoas teve tanto MAPE quanto o RMSE médios altos. O estado do Maranhão obteve o maior RMSE médio. O estado da Paraíba teve, em média, as duas métricas baixas.

Tabela 6.6 – Tabela contendo as métricas MAPE e RMSE dos modelos de suavização exponencial das séries dos estados da região Nordeste

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Alagoas	8,03%	16,34	50,38%	54,82	117,65%	84,97
Bahia	4,37%	37,37	5,12%	43,72	4,57%	47,67
Ceará	2,96%	6,92	4,86%	11,36	6,46%	19,08
Maranhão	67,68%	70,85	15,71%	18,93	15,88%	24,45
Paraíba	6,61%	2,66	4,66%	2,15	2,86%	1,28
Pernambuco	5,18%	18,32	1,54%	5,28	3,59%	13,19
Piauí	15,22%	2,75	8,34%	2,00	18,78%	3,59
Rio G. do Norte	2,88%	3,97	2,77%	3,69	3,45%	3,88
Sergipe	7,20%	10,11	6,73%	7,81	10,49%	10,19
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Alagoas	9,60%	7,96	43,65%	54,41	45,86%	43,70
Bahia	5,55%	51,63	3,93%	37,44	4,71%	43,57
Ceará	35,90%	61,99	3,53%	8,97	10,74%	21,66
Maranhão	2,68%	33,74	23,33%	222,07	25,06%	74,01
Paraíba	6,61%	2,66	4,66%	2,15	5,08%	2,18
Pernambuco	7,00%	29,39	5,37%	20,44	4,54%	17,32
Piauí	14,68%	2,56	5,44%	1,23	12,49%	2,43
Rio G. do Norte	8,00%	8,98	4,16%	5,39	4,25%	5,18
Sergipe	5,60%	6,29	10,59%	11,94	8,12%	9,27

A tabela 6.7 apresenta o tipo de modelo de suavização exponencial utilizados para prever dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste. Pode-se observar nesta tabela que foi utilizado o mesmo modelo em todos os cenários para as séries de Goiás e Mato Grosso. Nos dois primeiros cenários da série do Mato Grosso do Sul não foram considerados a característica de tendência. No quarto cenário de conjunto teste, utilizando os dados de 2020, a tendência considerado no Distrito Federal foi aditiva amortecida. Todas as sazonalidades são aditivas.

Tabela 6.7 – Tabela contendo o tipo de modelo de suavização exponencial das séries dos estados da região Centro-Oeste.

Teste	2017	2018	2019	2020	2021
Distrito-Federal	(A,A)	(A,A)	(A,A)	(A _d ,A)	(A,A)
Goiás	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Mato Grosso	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Mato Grosso do Sul	(N,A)	(N,A)	(A,A)	(A,A)	(A,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

Na tabela 6.8, observa-se as métricas do tipo de modelo de suavização exponencial utilizados para prever dados de consumo de energia elétrica do setor industrial dos estados da região Centro-Oeste.

Tabela 6.8 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Centro-Oeste

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Distrito-Federal	6,72%	3,44	7,95%	4,06	13,65%	6,38
Goiás	1,50%	10,03	3,94%	24,50	6,99%	35,46
Mato Grosso	11,39%	20,36	2,09%	4,67	3,10%	6,74
Mato Grosso do Sul	7,07%	7,31	5,01%	6,76	4,41%	5,94
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Distrito-Federal	13,24%	8,23	3,61%	2,35	9,03%	4,89
Goiás	1,67%	9,88	1,82%	9,66	3,18%	17,91
Mato Grosso	2,83%	7,12	5,02%	10,07	4,89%	9,79
Mato Grosso do Sul	6,88%	9,41	2,33%	3,29	5,14%	6,54

Os modelos de suavização exponencial ajustados as séries temporais do consumo de energia elétrica para os estados do Espírito Santo, Rio de Janeiro e Minas Gerais não apresentaram tendência em nenhum dos cinco cenários, todavia, São Paulo considerou nos primeiros dois conjuntos teste uma tendência aditiva e nos outros conjuntos, tendência aditiva com amortecimento. Todas os modelos consideraram a sazonalidade aditiva (tabela 6.9).

Tabela 6.9 – Tabela contendo o tipo de modelo Holt-Winters das séries dos estados da região Sudeste.

Teste	2017	2018	2019	2020	2021
São Paulo	(A,A)	(A,A)	(A_d,A)	(A_d,A)	(A_d,A)
Espírito Santo	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Minas Gerais	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)
Rio de Janeiro	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

Os modelos de suavização exponencial ajustados aos de consumo de energia elétrica de Minas Gerais e São Paulo apresentaram os maiores valores de RMSE médio da região sudeste (tabela 6.10). Os valores de MAPE médio obtido para os estados da região sudeste foram inferior a 6,5% (tabela 6.10).

Tabela 6.10 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Sudeste.

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
São Paulo	3,67%	176,25	4,62%	21,14	2,15%	109,08
Espírito Santo	3,64%	13,97	3,94%	24,50	11,77%	43,07
Minas Gerais	2,45%	68,31	3,34%	114,80	5,05%	142,25
Rio de Janeiro	6,64%	54,58	4,99%	41,56	4,67%	38,30

Continua na próxima página

Tabela 6.10 - Continuação da tabela.

Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
São Paulo	8,08%	354,86	2,52%	151,90	4,21%	162,65
Espírito Santo	7,41%	28,22	4,71%	19,77	6,29%	25,91
Minas Gerais	6,32%	178,51	3,33%	109,49	4,10%	122,67
Rio de Janeiro	7,47%	54,56	2,74%	22,75	5,30%	42,35

Os tipos de modelos de suavização exponencial obtidos para o consumo de energia elétrica da região Sul foram apresentados na tabela 6.11. Nesta tabela, pode-se observar que os modelos ajustados aos estados do Paraná e Santa Catarina Consideram a tendência e a sazonalidade aditivas.

Tabela 6.11 – Tabela contendo o tipo de modelo Holt-Winters das séries dos estados da região Sul.

Teste	2017	2018	2019	2020	2021
Paraná	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Santa Catarina	(A,A)	(A,A)	(A,A)	(A,A)	(A,A)
Rio G. do Sul	(N,A)	(N,A)	(N,A)	(N,A)	(N,A)

N - Nenhuma, A - Aditiva, M - Multiplicativa e A_d - Aditiva com amortecimento.

Os estados entregaram bons resultados entre as métricas médias. O menor MAPE médio encontrado para o modelo ajustado ao estado do Paraná e o menor RMSE médio foi entregue pelo estado de Santa Catarina. Os modelos ajustados apresentaram um MAPE médio inferior a 5%.

Tabela 6.12 – Tabela contendo as métricas MAPE e RMSE dos modelos Holt-Winters das séries dos estados da região Sul.

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Paraná	2,72%	34,78	3,48%	43,61	2,94%	38,34
Santa Catarina	4,12%	37,40	2,42%	23,91	3,05%	30,61
Rio G. do Sul	3,65%	34,72	4,04%	39,23	5,38%	48,07
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Paraná	4,92%	70,01	2,88%	39,56	3,39%	45,26
Santa Catarina	8,59%	84,54	1,77%	21,48	3,99%	39,59
Rio G. do Sul	7,05%	76,05	3,83%	43,99	4,79%	48,41

6.2 Modelos de Box e Jenkins

No capítulo 3, mais precisamente na seção 3.4.3, foi visto conceitos sobre a metodologia dos modelos de Box e Jenkins. A tabela 6.13 mostra o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ de cada série regional e nacional nos cinco cenários de teste. Observe que o modelo em alguns momentos varia de acordo com o conjunto de teste. Em todos os cenários foi necessário pelo menos um tipo de diferenciação.

Tabela 6.13 – Tabela com o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries de nível Brasil e regionais.

Teste	2017	2018	2019	2020	2021
Brasil	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 2)
Norte	(1, 0, 1)(0, 1, 1)	(1, 0, 1)(0, 1, 1)	(0, 1, 1)(1, 0, 0)	(0, 1, 2)(1, 0, 0)	(0, 1, 0)(1, 0, 0)
Nordeste	(1, 1, 0)(0, 1, 1)	(2, 1, 0)(0, 1, 2)	(1, 1, 2)(0, 1, 1)	(2, 1, 0)(0, 1, 1)	(1, 1, 1)(2, 0, 0)
Centro-Oeste	(0, 1, 1)(1, 1, 0)	(0, 1, 1)(1, 1, 0)	(0, 1, 1)(1, 1, 0)	(1, 0, 1)(1, 1, 0)	(1, 0, 1)(1, 1, 0)
Sudeste	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 1)	(0, 1, 0)(0, 1, 1)	(1, 0, 0)(1, 1, 0)	(0, 1, 0)(1, 0, 0)
Sul	(0, 1, 1)(1, 1, 2)	(1, 0, 1)(1, 1, 2)	(3, 0, 0)(0, 1, 2)	(3, 0, 0)(0, 1, 2)	(3, 0, 0)(0, 1, 2)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

Na tabela 6.14, pode-se observar as métricas do modelo SARIMA(p, d, q)(P, D, Q)₁₂ utilizados para prever o consumo de energia elétrica do setor industrial das regiões e do Brasil. O menor MAPE médio foi calculado para região Centro-Oeste, corroborando com o método fornecido pelo modelo de suavização exponencial, o pior foi visto na região Norte. A série totalmente agregada apresentou o maior RMSE médio, contudo é necessário reiterar que esta métrica é sensível a magnitude dos dados, dessa forma, é interessante usa-lá para comparar tipos de métodos empregados sobre a mesma série histórica.

Tabela 6.14 – Tabela com as métricas MAPE e RMSE dos modelos SARIMA dos dados nacionais e regionais

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,95%	465,64	1,21%	238,10	2,25%	364,73
Norte	2,40%	35,32	17,35%	208,73	18,42%	253,87
Nordeste	3,06%	66,46	4,88%	99,35	4,81%	100,72
Centro-Oeste	5,15%	41,81	3,10%	26,39	2,02%	21,74
Sudeste	4,04%	331,06	1,38%	127,11	4,71%	393,85
Sul	4,87%	119,44	2,04%	76,31	2,21%	73,08
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	6,51%	954,62	2,83%	519,80	3,15%	508,58
Norte	8,19%	108,08	5,99%	97,78	10,47%	140,76
Nordeste	6,45%	136,70	8,76%	181,45	5,59%	116,94
Centro-Oeste	4,21%	39,31	2,62%	23,43	3,42%	30,54
Sudeste	7,22%	547,71	2,92%	307,09	4,05%	341,36
Sul	6,63%	218,32	4,84%	185,05	4,12%	134,44

O modelo SARIMA obtido para a série temporal do consumo de energia elétrica do estado do Amapá não apresentou nenhum processo de diferenciação (tabela 6.15). O estado de Rondônia, em seus quatro primeiros cenários, apresentou o menor AIC_c utilizando modelos ARIMA, ou seja, não considerou a parte sazonal, além disso, os modelos foram iguais.

Tabela 6.15 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Norte.

Teste	2017	2018	2019	2020	2021
Acre	(0, 1, 1)(1, 0, 1)	(0, 1, 1)(1, 0, 1)	(0, 1, 2)(1, 0, 1)	(2, 1, 1)(0, 0, 2)	(2, 1, 1)(0, 0, 2)
Amapá	(3, 0, 0)(0, 0, 2)	(2, 1, 0)(0, 0, 2)	(2, 1, 1)(0, 0, 2)	(2, 1, 0)(0, 0, 2)	(2, 1, 1)(0, 0, 1)
Amazonas	(1, 1, 2)(0, 1, 1)	(1, 1, 2)(1, 1, 1)	(1, 1, 2)(1, 1, 1)	(1, 1, 2)(1, 1, 1)	(0, 1, 1)(2, 0, 0)
Pará	(3, 0, 0)(1, 1, 2)	(3, 0, 0)(1, 1, 2)	(0, 1, 1)(1, 0, 0)	(0, 1, 0)(1, 0, 0)	(2, 1, 0)(2, 0, 0)
Rondônia	(2, 1, 1)(0, 0, 0)	(2, 1, 1)(0, 0, 0)	(2, 1, 0)(0, 0, 0)	(2, 1, 0)(0, 0, 0)	(2, 1, 3)(0, 0, 1)
Roraima	(3, 1, 0)(2, 0, 0)	(4, 1, 1)(2, 0, 0)	(2, 1, 1)(2, 0, 0)	(3, 1, 0)(2, 0, 0)	(4, 1, 0)(2, 0, 0)
Tocantins	(2, 0, 1)(0, 1, 2)	(1, 0, 1)(0, 1, 1)	(1, 0, 1)(0, 1, 1)	(1, 0, 1)(0, 1, 1)	(1, 0, 1)(0, 1, 1)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

O menor MAPE médio foi encontrado no estado de Rondônia e o maior em Roraima. Além disso, sob a métrica RMSE, é notável uma melhora na modelagem do estado do Acre em comparação com o método de suavização exponencial, todavia, uma piora para o estado do Pará (Tabela 6.16).

Tabela 6.16 – Tabela com as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Norte

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Acre	11,21%	0,434	14,04%	0,464	9,62%	0,354
Amapá	27,22%	2,03	8,73%	0,998	3,83%	0,435
Amazonas	11,30%	17,37	4,42%	7,01	3,96%	6,06
Pará	1,91%	25,86	22,08%	209,86	22,11%	249,44
Rondônia	6,45%	2,66	5,07%	2,28	3,05%	1,34
Roraima	8,93%	0,210	15,03%	0,472	28,79%	0,558
Tocantins	9,80%	3,24	6,90%	2,24	13,22%	4,07
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Acre	4,88%	0,179	9,59%	0,414	9,87%	0,369
Amapá	1,44%	1,54	31,03%	3,12	14,45%	1,62
Amazonas	10,90%	18,50	6,27%	11,39	7,37%	12,07
Pará	10,80%	117,42	4,15%	59,89	12,21%	132,49
Rondônia	6,40%	2,92	11,87%	5,02	6,57%	2,84
Roraima	19,92%	0,431	6,71%	0,139	15,88%	0,362
Tocantins	9,17%	2,75	10,60%	3,81	9,94%	3,22

Nos dois primeiros cenários, o estado do Maranhão utilizou uma dupla diferenciação simples, em contrapartida, no primeiro conjunto teste, o estado da Bahia não usufruiu de nenhuma diferenciação (tabela 6.17). O modelo SARIMA se ajustou melhor no estado da Paraíba,

observando a métrica MAPE (tabela 6.18). Comparando com a tabela 6.6, que exibe as métricas para o método de suavização exponencial, o modelo SARIMA apresentou melhores RMSE médios para os estados de Sergipe, Maranhão e Ceará, somente.

Tabela 6.17 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Nordeste.

Teste	2017	2018	2019	2020	2021
Alagoas	(0, 1, 1)(0, 0, 1)	(0, 1, 1)(0, 0, 1)	(1, 0, 0)(0, 0, 1)	(1, 0, 1)(0, 0, 1)	(1, 1, 1)(0, 0, 0)
Bahia	(3, 0, 0)(2, 0, 0)	(0, 1, 1)(0, 0, 2)	(2, 1, 0)(2, 0, 0)	(2, 1, 0)(2, 0, 0)	(2, 1, 0)(2, 0, 0)
Ceará	(0, 1, 0)(1, 0, 0)	(0, 1, 0)(2, 0, 0)	(0, 1, 0)(2, 0, 0)	(0, 1, 1)(0, 0, 2)	(0, 1, 0)(0, 0, 1)
Maranhão	(3, 2, 0)(2, 0, 0)	(3, 2, 0)(2, 0, 0)	(0, 1, 0)(2, 0, 0)	(0, 1, 0)(2, 0, 0)	(0, 1, 0)(2, 0, 0)
Paraíba	(1, 1, 1)(0, 0, 2)	(1, 1, 1)(0, 0, 2)	(1, 1, 1)(0, 0, 2)	(1, 1, 1)(0, 0, 2)	(1, 1, 1)(2, 0, 0)
Pernambuco	(1, 1, 0)(1, 0, 1)	(0, 1, 1)(1, 0, 0)	(1, 1, 2)(1, 0, 0)	(1, 1, 2)(1, 0, 0)	(1, 1, 1)(1, 0, 0)
Piauí	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)
Rio G. do Norte	(2, 1, 0)(2, 0, 0)	(2, 1, 0)(2, 0, 0)	(2, 1, 0)(2, 0, 0)	(2, 1, 0)(2, 0, 0)	(2, 1, 1)(2, 0, 0)
Sergipe	(0, 1, 1)(2, 0, 0)	(0, 1, 1)(2, 0, 0)	(0, 1, 3)(2, 0, 0)	(0, 1, 3)(2, 0, 0)	(0, 1, 2)(2, 0, 0)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

Tabela 6.18 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Nordeste

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Alagoas	7,71%	17,31	5,06%	55,17	112,40%	81,01
Bahia	4,44%	41,91	3,58%	31,54	5,48%	52,31
Ceará	8,98%	22,33	3,97%	8,98	8,26%	21,60
Maranhão	60,88%	69,08	53,87%	63,48	7,89%	11,36
Paraíba	3,00%	4,44	4,24%	6,20	2,76%	3,82
Pernambuco	7,66%	21,22	2,70%	12,31	1,93%	6,67
Piauí	16,12%	2,96	9,89%	2,05	20,85%	4,02
Rio G. do Norte	2,92%	3,47	3,99%	4,83	3,85%	4,40
Sergipe	6,66%	8,59	6,04%	7,26	9,42%	9,06

Continua na próxima página

Tabela 6.18 - Continuação da tabela.

Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Alagoas	85,02%	53,41	40,77%	52,29	50,19%	51,84
Bahia	5,67%	50,49	3,02%	29,15	4,44%	41,08
Ceará	36,60%	62,91	12,05%	27,13	13,97%	28,59
Maranhão	10,32%	15,10	8,33%	13,93	28,26%	34,59
Paraíba	10,37%	14,22	4,11%	5,34	4,90%	6,80
Pernambuco	6,91%	28,19	9,57%	35,89	5,75%	20,86
Piauí	21,89%	3,73	5,85%	1,35	14,92%	2,82
Rio G. do Norte	7,55%	8,90	6,37%	7,67	4,94%	5,85
Sergipe	5,47%	5,56	12,71%	14,36	8,06%	8,97

Em quase totalidade dos cenários foi necessário uma diferenciação simples, a menos no estado do Mato Grosso para o conjunto teste com os dados de 2021 (Tabela 6.19). Observando o RMSE médio, no Distrito-Federal e Mato Grosso os modelos SARIMA entregaram melhor previsão.

Tabela 6.19 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Centro-Oeste.

Teste	2017	2018	2019	2020	2021
Distrito-Federal	(1, 1, 0)(1, 0, 0)	(0, 1, 1)(1, 0, 0)	(1, 1, 2)(1, 0, 0)	(0, 1, 1)(1, 0, 0)	(0, 1, 1)(1, 0, 0)
Goiás	(0, 1, 1)(0, 0, 1)	(0, 1, 1)(0, 0, 1)	(0, 1, 1)(0, 0, 1)	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)
Mato Grosso	(0, 1, 2)(0, 1, 1)	(1, 1, 0)(1, 1, 1)	(1, 1, 0)(1, 1, 1)	(1, 1, 0)(1, 1, 1)	(1, 0, 2)(0, 1, 1)
Mato Grosso do Sul	(2, 1, 2)(1, 0, 0)	(2, 1, 2)(1, 0, 0)	(2, 1, 2)(1, 0, 0)	(0, 1, 2)(2, 0, 0)	(1, 1, 2)(2, 0, 0)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

Tabela 6.20 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Centro-Oeste

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Distrito-Federal	8,05%	3,83	4,87%	2,60	8,81%	4,42
Goiás	4,13%	21,08	5,59%	34,54	5,12%	29,80
Mato Grosso	7,90%	14,41	2,27%	4,97	2,87%	6,37
Mato Grosso do Sul	6,94%	7,28	5,27%	6,76	5,57%	6,61

Continua na próxima página.

Tabela 6.20 - Continuação da tabela.

Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Distrito-Federal	12,94%	7,79	4,79%	3,15	7,89%	4,36
Goiás	3,05%	17,43	3,01%	16,13	4,18%	23,80
Mato Grosso	2,64%	6,69	4,02%	8,96	3,94%	8,28
Mato Grosso do Sul	6,24%	8,93	2,45%	3,87	5,29%	6,69

O modelo ajustado aos dados de consumo de energia apresentou características de não-estacionariedade e, portanto, foi necessário diferenciar a série temporal como pode-se verificar na tabela 6.21.

Tabela 6.21 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Sudeste.

Teste	2017	2018	2019	2020	2021
São Paulo	(1, 1, 2)(0, 1, 2)	(1, 1, 2)(0, 1, 1)	(0, 1, 1)(0, 1, 1)	(0, 1, 1)(0, 1, 1)	(1, 1, 1)(0, 1, 2)
Espírito Santo	(0, 1, 0)(0, 0, 1)	(0, 1, 0)(0, 0, 1)	(0, 1, 0)(0, 0, 1)	(0, 1, 0)(0, 0, 1)	(0, 1, 0)(0, 0, 2)
Minas Gerais	(1, 0, 1)(2, 0, 0)	(1, 0, 1)(2, 0, 0)	(2, 0, 0)(2, 0, 0)	(1, 0, 0)(2, 0, 0)	(1, 0, 2)(2, 0, 2)
Rio de Janeiro	(0, 1, 1)(0, 0, 2)	(1, 1, 2)(0, 0, 2)	(1, 1, 2)(0, 0, 2)	(0, 1, 1)(0, 0, 2)	(0, 1, 1)(0, 0, 2)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

O estado de Minas Gerais, apresentou o menor MAPE médio, o mesmo aconteceu para o modelo de suavização exponencial, ademais, só nesse estado o modelo SARIMA apresentou melhor MAPE médio que o modelo de suavização exponencial (tabela 6.22).

Tabela 6.22 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Sudeste.

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
São Paulo	3,50%	166,11	2,22%	108,74	2,04%	105,70
Espírito Santo	5,06%	21,34	6,93%	28,04	10,53%	40,16
Minas Gerais	2,38%	65,20	3,59%	108,84	3,28%	97,43
Rio de Janeiro	5,63%	50,51	5,64%	47,58	4,80%	37,71
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
São Paulo	8,14%	355,87	5,95%	277,40	4,37%	202,76
Espírito Santo	10,45%	42,35	6,33%	26,37	7,86%	31,65
Minas Gerais	4,77%	135,34	5,32%	156,15	3,87%	112,59
Rio de Janeiro	8,65%	61,39	3,29%	30,35	5,60%	45,51

O estado do Rio Grande do Sul não utilizou nenhuma diferenciação simples, somente sazonal. Além disso, todas as séries contêm pelo menos um tipo de diferenciação (tabela 6.23).

Tabela 6.23 – Tabela contendo o tipo de modelo SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Sul.

Teste	2017	2018	2019	2020	2021
Paraná	(2,0,0)(0,1,2)	(2,0,0)(0,1,2)	(2,0,1)(0,1,1)	(2,0,1)(0,1,1)	(3,1,0)(1,0,1)
Santa Catarina	(0,1,1)(0,1,1)	(1,0,2)(0,1,1)	(1,0,1)(0,1,2)	(2,0,2)(0,1,2)	(1,0,1)(0,1,1)
Rio G. do Sul	(2,0,2)(1,1,1)	(2,0,2)(1,1,1)	(2,0,0)(1,1,1)	(2,0,1)(1,1,2)	(2,0,0)(1,1,2)

Parâmetros: p - ordem autorregressiva, q - ordem de médias móveis, d - quantidade de diferenças simples, P - ordem autorregressiva sazonal, Q - ordem autorregressiva sazonal e D - quantidade de diferença sazonal.

O menor MAPE médio foi encontrado no estado do Paraná. Todos os RMSE médios foram maiores em comparação com os modelos de suavização exponencial (tabela 6.24).

Tabela 6.24 – Tabela contendo as métricas MAPE e RMSE dos modelos SARIMA(p, d, q)(P, D, Q)₁₂ das séries dos estados da região Sul.

Teste	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Paraná	2,96%	36,57	4,06%	50,59	3,29%	38,12
Santa Catarina	4,37%	39,41	2,26%	21,95	2,91%	28,91
Rio G. do Sul	2,85%	27,47	4,59%	42,69	3,88%	39,20
Teste	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Paraná	5,51%	77,19	2,98%	38,93	3,76%	48,28
Santa Catarina	8,43%	85,60	4,51%	51,07	4,50%	45,39
Rio G. do Sul	7,47%	76,51	5,97%	63,11	4,95%	49,80

6.3 Comparações entre as Abordagens em Séries Temporais Hierárquicas

Esta seção será destinada para as análises e comparações entre as abordagens em séries temporais hierárquicas. Foi proposto três tipos de hierarquia, a primeira com um nível que contém as séries de nível Brasil e regiões. A segunda com dois níveis, contendo as séries do Brasil, regiões e estados. A terceira, que se encontra em anexo, com um nível, contudo, a hierarquia se restringe a cada região, logo, terão cinco hierarquias separadas das regiões com seus respectivos estados. Cada hierarquia será aplicado dois métodos preditivos, em dois cenários diferentes, o primeiro cenário será utilizado somente o método de suavização exponencial, no segundo cenário, o método de Box e Jenkins. A forma de verificar qualidade de previsão é verificando as métricas MAPE e RMSE.

6.3.1 Hierarquia Brasil-Regiões

Nesta subseção, será exposto as análises e previsões para a hierarquia de um nível contendo a série de consumo de energia elétrica do setor industrial brasileiro e regiões (figura 6.1).

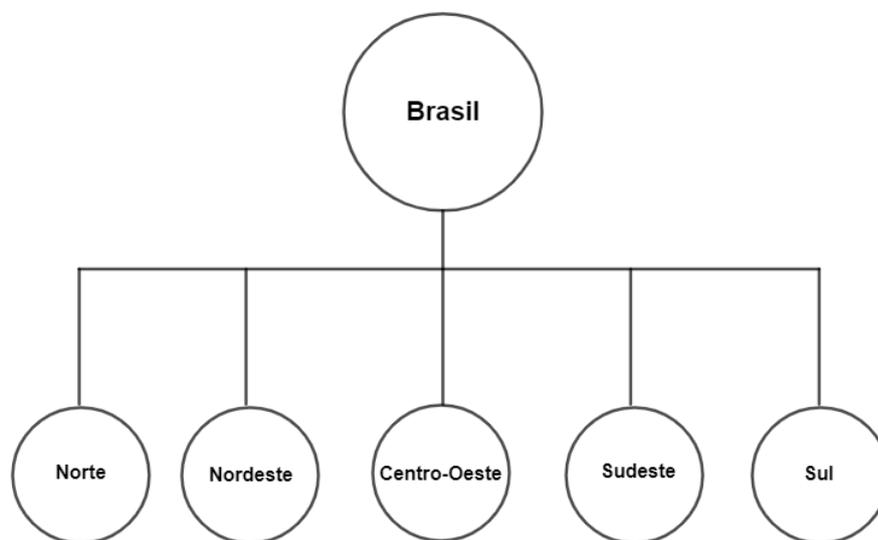


Figura 6.1 – Esquema hierárquico de um nível Brasil e Regiões.

Fonte: Autor (2022)

A tabela 6.25 apresenta as métricas MAPE e RMSE para o método preditivo de suavização exponencial, o MAPE médio obtido pelas abordagens para o nível mais agregado é inferior a 4%. Ademais, abordagem *top-down* forneceu o menor valor do MAPE médio e a menor média RMSE, portanto, o modelo com melhor capacidade preditiva para esta primeira estrutura hierárquica. Por outro lado, a tabela 6.26 mostra que abordagem híbrida integrada aos modelos de Box e Jenkins apresenta a melhor capacidade preditiva, no MAPE médio, mas no RMSE médio, a abordagem *top-down* apresentou menor métrica.

Tabela 6.25 – Tabela das métricas MAPE e RMSE para os dados do Brasil e regiões utilizando o método de suavização exponencial.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,43%	367,85	1,86%	305,40	3,05%	477,50
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,26%	924,58	2,79%	472,92	3,28%	509,65

Continua na próxima página.

Tabela 6.25 - Continuação da tabela.

	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,85%	426,19	1,46%	258,89	2,27%	364,55
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,39%	936,34	3,03%	503,98	3,20%	497,59
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,60%	390,45	1,70%	284,85	2,73%	431,71
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,31%	929,13	2,88%	483,94	3,24%	504,02
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,64%	397,24	1,68%	280,43	2,65%	419,53
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,32%	929,77	2,91%	488,91	3,24%	503,18

Tabela 6.26 – Tabela das métricas MAPE e RMSE para os dados do Brasil e regiões utilizando o método de Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,84%	437,99	1,38%	261,81	1,98%	330,04
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,62%	869,18	3,32%	678,96	3,03%	515,60
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,95%	465,64	1,21%	238,10	2,25%	364,73
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,51%	954,62	2,58%	518,13	3,10%	508,24
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,88%	448,73	1,31%	251,74	2,09%	342,58
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,01%	900,71	2,99%	610,84	3,06%	510,92

Continua na próxima página.

Tabela 6.26 - Continuação da tabela.

	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Brasil	2,89%	451,70	1,28%	248,32	2,11%	345,04
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,05%	905,77	2,58%	598,16	2,98%	509,80

As figuras 6.2 e 6.3 exibem as comparações das previsões das abordagens para a hierarquia de um nível. Na figura 6.2, observa-se o cenário de previsão para o ano de 2017, além disso ambos os métodos preditivos estão exibindo previsões próximas e conseguem, apesar da subestimação, captar as características do conjunto teste.

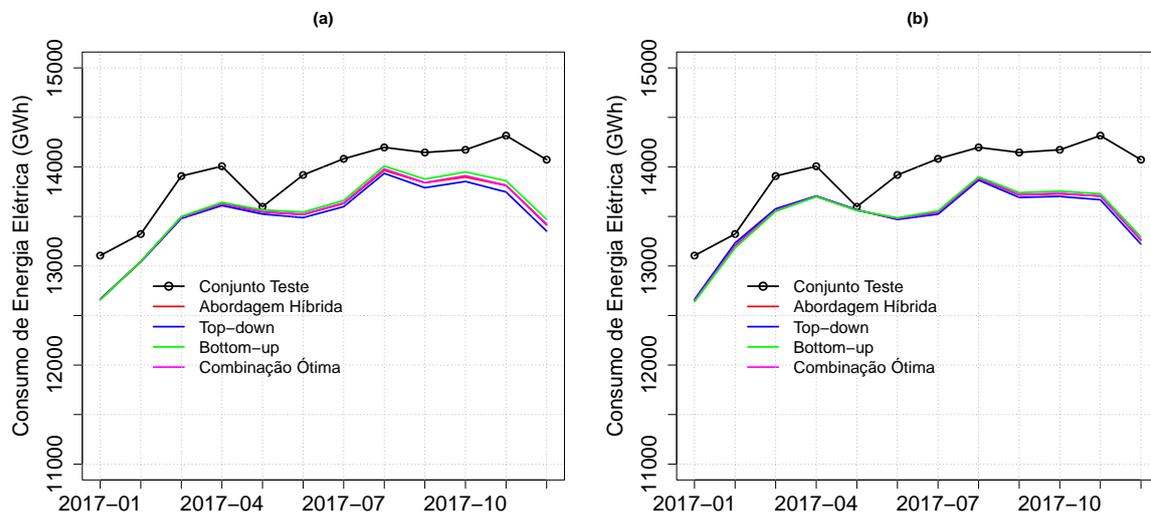


Figura 6.2 – (a) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de suavização exponencial para a hierarquia de um nível. (b) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de Box e Jenkins para a hierarquia de um nível.

Na figura 6.3, apresenta-se o cenário de previsão para o ano de 2021. Os métodos preditivos têm comportamento diferentes. O método de suavização exponencial capturou melhor as características do conjunto teste em comparação ao método de Box e Jenkins para o período de abril até setembro, doravante, observa-se um comportamento melhor do método de Box e Jenkins no fim do ano.

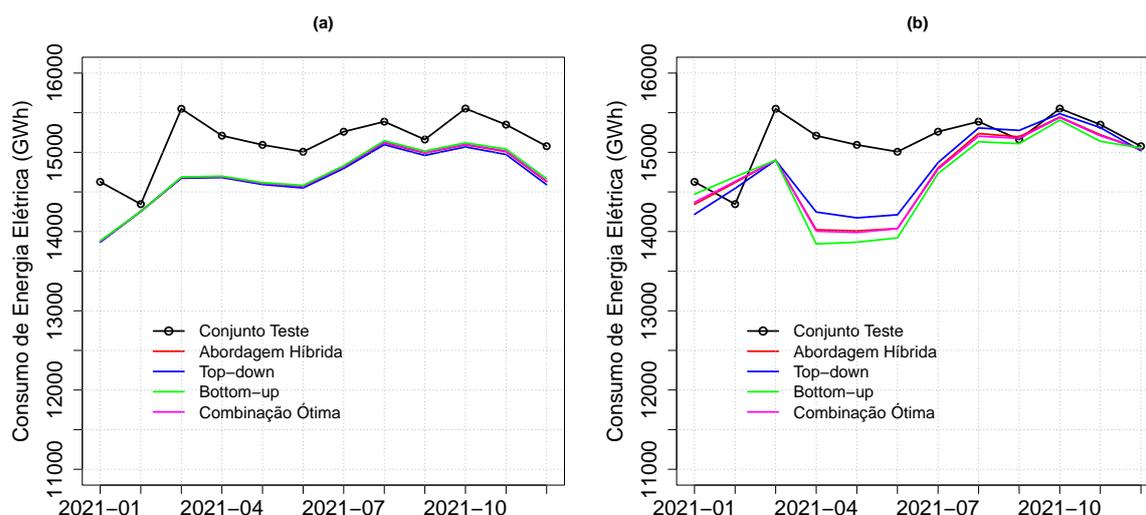


Figura 6.3 – (a) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de suavização exponencial para a hierarquia de um nível. (b) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de Box e Jenkins para a hierarquia de um nível.

6.3.2 Hierarquia Brasil-Regiões-Estados

Nesta subseção, serão apresentadas análises para a hierarquia de dois níveis contendo a série de consumo de energia elétrica do setor industrial brasileiro, região e estados. Nesta estrutura hierárquica, os estados são a base da hierarquia, no nível intermediário as regiões que agrega seus respectivos estados, já no nível totalmente agregado estão os dados nacionais (Brasil).

A tabela 6.27 mostra os valores das métricas MAPE e RMSE de cada cenário de conjunto de teste para os dados de consumo de energia elétrica do setor industrial nacional utilizando o método preditivo de suavização exponencial. A abordagem híbrida apresentou o menor valor para métrica RMSE médio, comparando as médias, seguido pela abordagem de combinação ótima. O MAPE médio das abordagens foram inferiores a 3,2%. A abordagem de combinação ótima apresentou a melhor capacidade preditiva com base na medida de precisão MAPE.

Tabela 6.27 – Tabela das métricas MAPE e RMSE para os dados de consumo de energia elétrica do setor industrial brasileiro utilizando o método de suavização exponencial na hierarquia de dois níveis.

Bottom-up	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,70%	409,76	2,09%	357,25	1,67%	310,59
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,74%	924,35	2,47%	428,05	2,93%	486,00

Continua na próxima página

Tabela 6.27 - Continuação da tabela.

Top-Down	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,85%	426,19	1,46%	258,89	2,27%	364,55
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,39%	936,34	3,03%	503,98	3,20%	497,59
Comb. Ótima	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,61%	396,51	2,08%	352,20	1,55%	296,43
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,83%	926,81	2,38%	415,29	2,89%	477,45
Híbrida	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,51%	382,44	1,54%	266,41	2,12%	341,14
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,81%	898,13	2,76%	467,87	2,95%	471,20

A tabela 6.28 apresenta os valores das métricas MAPE e RMSE de cada cenário do conjunto de teste para os dados de consumo de energia elétrica do setor industrial nacional utilizando o método preditivo de Box e Jenkins. O MAPE médio das abordagens foram inferiores a 3,14%. A abordagem híbrida apresentou o menor valor de MAPE e RMSE médios. Os menores valores de MAPE e RMSE, entre os conjuntos de teste, foram obtidos pela abordagem *top-down* em 2018.

Tabela 6.28 – Tabela das métricas MAPE e RMSE para os dados de consumo de energia elétrica do setor industrial brasileiro utilizando o método de Box e Jenkins na hierarquia de dois níveis.

Bottom-up	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,24%	357,16	2,38%	381,05	1,37%	246,25
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,35%	941,24	4,38%	736,14	3,14%	532,37
Top-Down	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,95%	465,64	1,21%	238,10	2,25%	364,73
	2020		2021		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	6,51%	954,62	2,58%	518,13	3,10%	508,24

Continua na próxima página

Tabela 6.28 - Continuação da tabela.

Comb. Ótima	2017		2018		2019	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,35%	371,95	2,22%	359,29	1,22%	241,11
	2020		2021		Média	
Brasil	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,58%	929,87	3,67%	656,90	3,01%	511,82
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	2,37%	377,89	1,42%	265,51	1,70%	273,24
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
	5,68%	901,91	3,39%	611,04	2,91%	485,92
	2020		2021		Média	

As figuras 6.4 apresenta a comparação das quatro abordagens em dois cenários distintos. A primeira figura mostra a comparação das abordagens pelo método de suavização exponencial e a segunda pelo método de Box e Jenkins para o conjunto de teste do ano de 2017. Nesta figura, pode-se observar que a trajetória dos valores previstos são parecidos entre os abordagens consideradas.

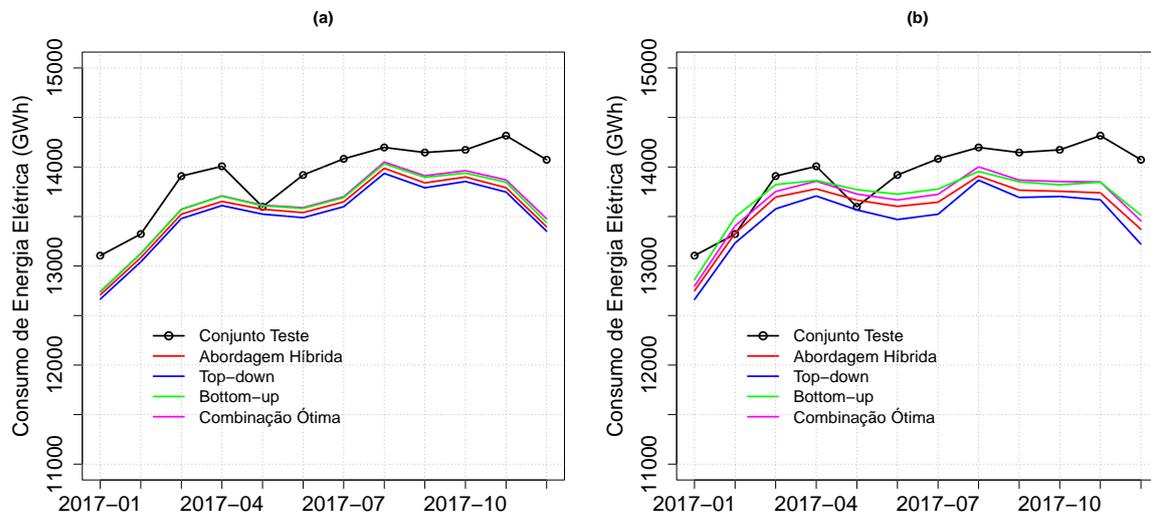


Figura 6.4 – (a) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de suavização exponencial para a hierarquia de dois níveis. (b) Comparação das abordagens na previsão do conjunto teste de 2017 para o método de Box e Jenkins para a hierarquia de dois níveis.

A figura 6.5 apresenta a comparação entre as abordagens em dois cenários distintos. A primeira figura exibe a comparação das abordagens pelo método de suavização exponencial e a segunda pelo método de Box e Jenkins para o conjunto de teste contendo o ano de 2021. A suavização exponencial capturou melhor as características do conjunto teste, contudo, entre os meses de setembro e dezembro, observa-se uma aproximação maior do método de Box e Jenkins no conjunto teste.

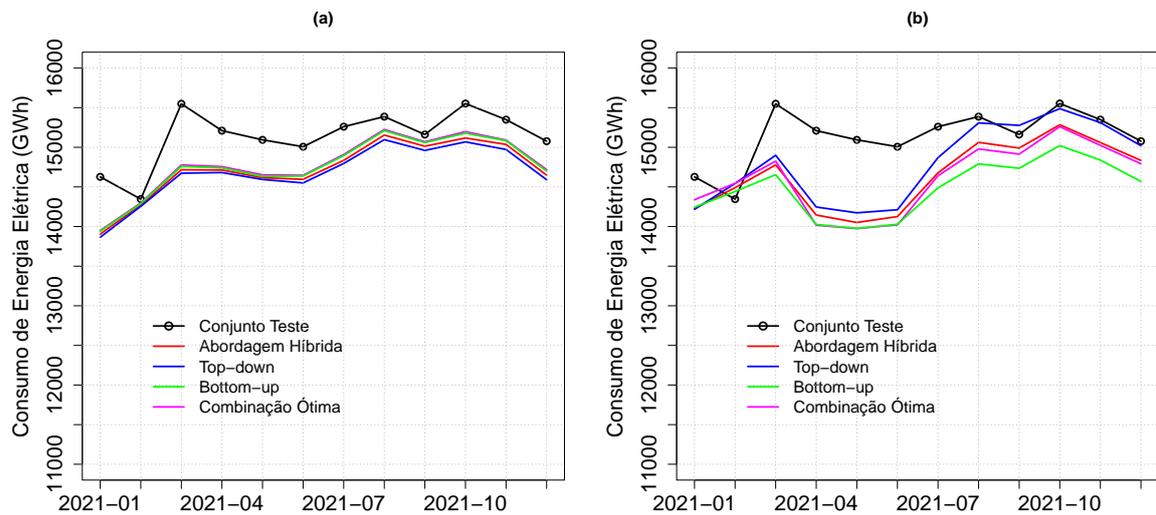


Figura 6.5 – (a) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de suavização exponencial para a hierarquia de dois níveis. (b) Comparação das abordagens na previsão do conjunto teste de 2021 para o método de Box e Jenkins para a hierarquia de dois níveis.

Conclusões

Neste trabalho foi considerada uma estrutura hierárquica para o consumo de energia elétrica do setor industrial brasileiro. A partir desta estrutura hierárquica foram comparadas as abordagens *top-down*, *bottom-up*, híbrida e de combinação ótima com intuito de avaliar a capacidade preditiva. Estas abordagens foram acopladas aos modelos preditivos de suavização exponencial e de Box e Jenkins. Além disso, foi proposta uma metodologia para abordagem híbrida. Inicialmente foi realizada uma análise exploratória das séries temporais por estado, região e Brasil, observar observar característica de tendência e sazonalidade contribuem para a aplicação dos métodos preditivos e para avaliar o consumo de energia elétrica em todos os níveis da estrutura hierárquica.

As abordagens foram comparadas em duas estruturas hierárquicas. A primeira considera o consumo de energia total Brasil e regiões e, a segunda, considerou estrutura com o Brasil (nível superior), as regiões (nível intermediário) e os estados brasileiros com o distrito federal (nível inferior) totalizando 33 séries temporais. Na literatura, não foi encontrado trabalhos referentes a esta estrutura hierárquica. Nesta estrutura é possível avaliar o consumo de energia elétrica e o desenvolvimento tecnológico industrial dos estados brasileiros.

A partir das estruturas hierárquicas consideradas neste trabalho, a hierarquia de dois níveis e a hierarquia de um nível, foram propostas oito formas de prever, já que, cada uma das formas é a combinação de abordagem e método preditivo. Ademais, foi proposto para cada análise cinco conjuntos de testes diferentes, cada um com doze observações, á saber: 2017, 2018, 2019, 2020 e 2021, com o intuito de comparar as métricas RMSE e MAPE médios entre os métodos.

Para a hierarquia de um nível (Brasil e regiões), os resultados mostraram que abordagem *top-down* via suavização exponencial apresentou melhores médias em ambas as métricas. Já no modelo de Box e Jenkins, a abordagem híbrida se destacou, em média, no MAPE e no RMSE médio a abordagem *top-down*. Além disso, os valores de MAPE médio entre as abordagens utilizadas foram inferiores a 3,4%.

Para a hierarquia de dois níveis (Brasil, regiões e estados), a abordagem híbrida via o método de Box e Jenkins apresentou os menores valores para as métricas consideradas, para o MAPE médio 2,91% e para o RMSE médio 485,92. Já para o método de suavização exponencial, a abordagem de combinação ótima entregou a melhor métrica MAPE médio (2,89%) e o método híbrido entregou o melhor RMSE (471,20). Todas as abordagens apresentaram um valor de MAPE médio inferior a 3,20%. O melhor método preditivo acoplado as abordagens foi o de suavização exponencial.

Os resultados indicam que a estrutura hierárquica com dois níveis tem a melhor capacidade preditiva para os dados de consumo de energia elétrica do setor industrial, com base nas

métricas consideradas. Nesta estrutura hierárquica, as abordagens integradas aos modelos preditivos conseguiram capturar a estrutura dos dados que envolvem as crises (2009 e 2016) e pela pandemia COVID-19. A abordagem híbrida apresentou a melhor capacidade preditiva entre as abordagens propostas, considerando o RMSE médio. Além disso, os resultados encontrados são úteis como instrumentos de apoio a tomada de decisão e contribuindo para planejamento energético do setor industrial no Brasil.

Uma questão interessante para pesquisas futuras é a introdução dos modelos de redes neurais para combinar com as abordagens já apresentadas neste trabalho. Outro trabalho interessante, seria avaliar o efeito de políticas eficiência energética de incentivos ao desenvolvimento do setor industrial considerando a estrutura hierárquica (Brasil, regiões e estados)

Referências bibliográficas

ATHANASOPOULOS, G.; AHMED, R. A.; HYNDMAN, R. J. Hierarchical forecasts for australian domestic tourism. *International Journal of Forecasting*, v. 25, n. 1, p. 146–166, 2009. ISSN 0169-2070. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169207008000691>>.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time Series Analysis: Forecasting and Control*. [S.l.]: Prentice-Hall, 2015.

BROWN, R. G. Statistical forecasting for inventory control. In: . [s.n.], 1960. Disponível em: <<https://api.semanticscholar.org/CorpusID:153020798>>.

CHATEAU, B.; LAPILLONNE, B. Long-term energy demand forecasting a new approach. *Energy Policy*, v. 6, n. 2, p. 140–157, 1978. ISSN 0301-4215. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0301421578900356>>.

CHEN, H.; BOYLAN, J. The effect of correlation between demands on hierarchical forecasting. *Advances in Business and Management Forecasting*, v. 6, n. 2, p. 173–188, 2009. ISSN 0301-4215. Disponível em: <[https://www.emerald.com/insight/content/doi/10.1108/S1477-4070\(2009\)0000006011/full/html](https://www.emerald.com/insight/content/doi/10.1108/S1477-4070(2009)0000006011/full/html)>.

CNI, C. N. da I. *Perfil Industrial do Estado da Bahia*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ba>>.

CNI, C. N. da I. *Perfil Industrial do Estado da Paraíba*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/pb>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Alagoas*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/al>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Goiás*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/go>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Minas Gerais*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/mg>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Pernambuco*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/pe>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Rondônia*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ro>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Roráima*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/rr>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Santa Catarina*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/sc>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Sergipe*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/se>>.

CNI, C. N. da I. *Perfil Industrial do Estado de São Paulo*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/sp>>.

CNI, C. N. da I. *Perfil Industrial do Estado de Tocantins*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/to>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Acre*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ac>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Amazonas*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/am>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Ceará*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ce>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Distrito Federal*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/df>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Espírito Santo*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/es>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Maranhão*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ma>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Mato Grosso*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/mt>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Mato Grosso do Sul*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/ms>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Paraná*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/pr>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Piauí*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/pi>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Rio de Janeiro*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/rj>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Rio Grande do Norte*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/rn>>.

CNI, C. N. da I. *Perfil Industrial do Estado do Rio Grande do Sul*. 2022. Disponível em: <<https://perfildaindustria.portaldaindustria.com.br/estado/rs>>.

DANGERFIELD, B. J.; MORRIS, J. S. Top-down or bottom-up: Aggregate versus disaggregate extrapolations. *International Journal of Forecasting*, v. 8, n. 2, p. 233–241, October 1992. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0169207092901210>>.

EPE. *Anuário Estatístico de Energia Elétrica*. 2022. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>

EPE. *BALANÇO ENERGÉTICO NACIONAL*. 2022. Disponível em: <<https://www.epe.gov.br/pt/areas-de-atuacao/energia-eletrica/expansao-da-geracao/fontes>>

EPE. *Matriz Energética e Elétrica*. 2022. Disponível em: <<https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>>

FLEITER, T. et al. Energy efficiency in the german pulp and paper industry – a model-based assessment of saving potentials. *Energy*, v. 40, n. 1, p. 84–99, 2012. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S036054421200120X>>.

GARDNER, E. S.; MCKENZIE, E. Energy efficiency in the german pulp and paper industry – a model-based assessment of saving potentials. *Energy*, v. 31, n. 10, p. 1237–1246, 1985. Disponível em: <<https://doi.org/10.1287/mnsc.31.10.1237>>.

GHEDAMSI, R. et al. Modeling and forecasting energy consumption for residential buildings in algeria using bottom-up approach. *Energy and Buildings*, v. 121, p. 309–317, 2016. ISSN 0378-7788. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S037877881530462X>>.

GRANGER C. W. J.; NEWBOLD, P. *Forecasting Economic Time Series*. [S.l.]: Academic Press, New York, 1977.

HERBST, A. et al. Introduction to energy systems modelling. *Swiss Journal of Economics and Statistics*, Springer, Heidelberg, v. 148, n. 2, p. 111–135, 2012. ISSN 2235-6282. Disponível em: <<http://hdl.handle.net/10419/185997>>.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, v. 20, n. 1, p. 5–10, 1957. ISSN 0169-2070. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169207003001134>>.

HUANG, Y.-H.; CHANG, Y.-L.; FLEITER, T. A critical analysis of energy efficiency improvement potentials in taiwan's cement industry. *Energy Policy*, v. 96, p. 14–26, 2016. ISSN 0301-4215. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0301421516302555>>.

HYNDMAN, R. J. et al. Optimal combination forecasts for hierarchical time series. *Computational Statistics Data Analysis*, v. 55, n. 9, p. 2579–2589, 2011. ISSN 0167-9473. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167947311000971>>.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2nd. ed. Australia: OTexts, 2018. Disponível em: <<https://otexts.com/fpp2/index.html>>.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for r. *Journal of Statistical Software*, v. 27, n. 3, p. 1–22, 2008. Disponível em: <https://www.jstatsoft.org/index.php/jss/article/view/v027i03>.

HYNDMAN, R. J.; LEE, A. J.; WANG, E. Fast computation of reconciled forecasts for hierarchical and grouped time series. *Computational Statistics Data Analysis*, v. 97, p. 16–32, 2016. ISSN 0167-9473. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016794731500290X>.

KOLASSA, S.; HYNDMAN, R. Do we want coherent hierarchical forecasts, or minimal maps or maes? (we won't get both!). *International Journal of Forecasting*, v. 39, n. 4, p. 1512–1517, 2023. ISSN 0169-2070. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169207022001492>.

LEE, C.-Y.; HUH, S.-Y. Forecasting the diffusion of renewable electricity considering the impact of policy and oil prices: The case of south korea. *Applied Energy*, v. 197, p. 29–39, 2017. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261917303707>.

MAÇAIRA, P.; ELSLAND, R.; OLIVEIRA, F. Forecasting residential electricity consumption: a bottom-up approach for brazil by region. *Energy Efficiency*, v. 13, p. 911–934, 2020. Disponível em: <https://link.springer.com/article/10.1007/s12053-020-09860-w#citeas>.

MAÇAIRA, P.; SOUZA, R.; OLIVEIRA, F. C. Modelling and forecasting the residential electricity consumption in brazil with pegels exponential smoothing techniques. *Procedia Computer Science*, v. 55, p. 328–335, 2015. ISSN 1877-0509. 3rd International Conference on Information Technology and Quantitative Management, ITQM 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S187705091501532X>.

MEIRA, E.; LILA, M. F.; OLIVEIRA, F. L. C. A novel reconciliation approach for hierarchical electricity consumption forecasting based on resistant regression. *Energy*, v. 269, p. 126794, 2023. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544223001883>.

MORETTIN P. A.; TOLOI, C. M. C. *Análise de Séries Temporais*. 3ed. ed. São Paulo: Blucher, 2018.

R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2022. Disponível em: <https://www.R-project.org/>.

SCHWARZKOPF, A. B.; TERSINE, R. J.; MORRIS, J. S. Top-down versus bottom-up: Forecasting strategies. *International Journal of Production Research*, International Journal of Production Research, v. 26, n. 11, p. 1833–1843, 1988. Disponível em: <https://doi.org/10.1590/S0101-74382007000300010>.

SILVA, F. et al. Statistical and artificial neural networks models for electricity consumption forecasting in the brazilian industrial sector. *Energies*, v. 15, p. 588, 01 2022. Disponível em: <https://doi.org/10.3390/en15020588>.

SILVA, F. L.; OLIVEIRA, F. L. C.; SOUZA, R. C. A bottom-up bayesian extension for long term electricity consumption forecasting. *Energy*, v. 167, p. 198–210, 2019. ISSN 0360-5442. Disponível em: <https://doi.org/10.1016/j.energy.2018.10.201>.

SILVA, F. L. et al. A bottom-up methodology for long term electricity consumption forecasting of an industrial sector - application to pulp and paper sector in brazil. *Energy*, v. 144, p. 1107–1118, 2018. ISSN 0360-5442. Disponível em: <<https://doi.org/10.1016/j.energy.2017.12.078>>.

SPILIOTIS, E. et al. Hierarchical forecast reconciliation with machine learning. *Applied Soft Computing*, v. 112, p. 107756, 2021. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494621006773>>.

TAIEB, S. B.; TAYLOR, J.; HYNDMAN, R. Hierarchical probabilistic forecasting of electricity demand with smart meter data. *Journal of the American Statistical Association*, v. 116, p. 1–36, 02 2020. Disponível em: <<https://doi.org/10.1080/01621459.2020.1736081>>.

WANG, X. et al. Forecast combinations: An over 50-year review. *International Journal of Forecasting*, 2022. ISSN 0169-2070. Disponível em: <<https://doi.org/10.1016/j.ijforecast.2022.11.005>>.

WICKRAMASURIYA, G. A. S. L.; HYNDMAN, R. J. Optimal forecast reconciliation for hierarchical and grouped time series through trace minimization. *Journal of the American Statistical Association*, Taylor Francis, v. 114, n. 526, p. 804–819, 2019. Disponível em: <<https://doi.org/10.1080/01621459.2018.1448825>>.

WICKRAMASURIYA, S. L.; TURLACH, B. A.; HYNDMAN, R. J. Optimal non-negative forecast reconciliation. *Statistics and Computing*, Springer, v. 30, n. 5, p. 1167–1182, 2020. Disponível em: <<https://link.springer.com/article/10.1007/s11222-020-09930-0>>.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. *Management Science*, v. 6, n. 3, p. 324–342, 1960. Disponível em: <<https://www.jstor.org/stable/2627346>>.

YI, B.-W.; XU, J.-H.; FAN, Y. Inter-regional power grid planning up to 2030 in china considering renewable energy development and regional pollutant control: A multi-region bottom-up optimization model. *Applied Energy*, v. 184, p. 641–658, 2016. ISSN 0306-2619. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261916316063>>.

9.1 Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Norte

Tabela 9.1 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Acre em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	2,01	0,09	0,30	1,70	2,54	14,74
2005	2,13	0,03	0,18	1,89	2,51	8,49
2006	2,19	0,07	0,27	1,85	2,59	12,39
2007	2,53	0,07	0,26	2,11	2,96	10,43
2008	2,71	0,05	0,23	2,45	3,11	8,50
2009	2,75	0,13	0,36	2,16	3,26	13,23
2010	2,98	0,07	0,26	2,42	3,22	8,84
2011	3,16	0,06	0,25	2,70	3,52	7,83
2012	3,65	0,15	0,38	3,16	4,54	10,47
2013	3,11	0,09	0,31	2,69	3,67	9,84
2014	3,08	0,06	0,25	2,62	3,43	8,01
2015	3,26	0,08	0,29	2,85	3,78	8,82
2016	3,30	0,11	0,34	2,75	3,82	10,17
2017	3,20	0,16	0,40	2,17	3,96	12,60
2018	2,95	0,11	0,33	2,29	3,37	11,30
2019	3,11	0,12	0,35	2,56	3,49	11,20
2020	3,41	0,05	0,23	3,07	3,77	6,77
2021	3,51	0,22	0,47	2,75	4,39	13,43

Tabela 9.2 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Amazonas em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	110,27	103,07	10,15	93,45	126,42	9,21
2005	117,81	76,40	8,74	105,33	130,11	7,42
2006	127,83	41,76	6,46	113,70	136,40	5,06
2007	132,00	78,11	8,84	114,04	143,45	6,70
2008	138,61	99,42	9,97	123,98	150,62	7,19
2009	123,39	117,53	10,84	107,12	142,71	8,79
2010	137,65	94,06	9,70	120,26	150,95	7,05
2011	147,95	70,91	8,42	133,82	161,33	5,69
2012	151,36	132,73	11,52	127,04	167,41	7,61
2013	148,66	87,72	9,37	131,56	163,29	6,30
2014	148,91	97,56	9,88	126,41	162,27	6,63
2015	139,19	109,81	10,48	112,97	150,85	7,53
2016	129,32	385,97	19,65	91,53	167,02	15,19
2017	132,88	68,38	8,27	122,16	151,11	6,22
2018	136,89	78,99	8,89	119,26	149,42	6,49
2019	137,82	83,88	9,16	123,69	150,91	6,65
2020	138,45	432,11	20,79	91,78	160,11	15,01
2021	152,19	157,48	12,55	129,75	165,69	8,25

Tabela 9.3 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Rondônia em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	18,41	2,08	1,44	15,49	20,56	7,83
2005	19,85	1,58	1,26	16,71	21,19	6,34
2006	19,29	2,49	1,58	17,22	21,66	8,19
2007	22,59	6,76	2,60	19,49	27,28	11,51
2008	25,07	0,99	0,99	23,28	26,73	3,96
2009	26,73	11,47	3,39	20,49	31,36	12,67
2010	32,84	7,36	2,71	27,31	36,13	8,26
2011	36,02	7,27	2,70	31,91	39,78	7,48
2012	47,30	17,46	4,18	41,52	56,19	8,84
2013	49,88	98,44	9,92	42,81	76,72	19,89

Continua na próxima página.

Tabela 9.3 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	46,08	5,36	2,32	40,73	49,19	5,02
2015	37,53	3,17	1,78	35,35	41,10	4,74
2016	34,51	1,28	1,13	32,27	36,09	3,28
2017	35,32	7,17	2,68	30,69	38,81	7,58
2018	37,54	5,02	2,24	34,18	41,13	5,97
2019	37,95	1,73	1,31	36,01	40,50	3,47
2020	39,28	6,83	2,61	34,96	42,68	6,65
2021	37,28	9,06	3,01	30,09	41,01	8,07

Na tabela 9.4, é exibido o resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado do Roraima.

Tabela 9.4 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Roraima em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	1,58	0,10	0,32	1,04	2,05	20,21
2005	1,09	0,05	0,23	0,46	1,27	20,90
2006	1,19	0,04	0,19	0,84	1,66	16,33
2007	1,22	0,01	0,07	1,10	1,35	5,84
2008	1,28	0,01	0,09	1,18	1,47	7,34
2009	1,26	0,01	0,09	1,12	1,42	6,97
2010	1,43	0,02	0,15	1,23	1,73	10,77
2011	1,32	0,02	0,12	1,12	1,48	9,42
2012	1,55	0,04	0,20	1,31	2,03	12,92
2013	1,50	0,03	0,16	1,30	1,91	10,95
2014	1,67	0,05	0,23	1,19	2,01	13,87
2015	1,90	0,08	0,28	1,58	2,66	14,93
2016	2,17	0,01	0,10	2,07	2,38	4,40
2017	2,01	0,04	0,20	1,70	2,29	9,97
2018	2,39	0,12	0,35	1,89	3,16	14,45
2019	1,90	0,10	0,31	1,47	2,42	16,37
2020	1,88	0,04	0,19	1,55	2,13	10,22
2021	1,89	0,03	0,17	1,66	2,25	8,91

Tabela 9.5 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Pará em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	762,26	1557,74	39,47	682,27	829,60	5,18
2005	782,51	368,46	19,20	756,44	813,70	2,45
2006	823,89	950,45	30,83	744,70	856,82	3,74
2007	863,41	1189,26	34,49	781,07	902,18	3,99
2008	882,29	1016,10	31,88	824,32	945,23	3,61
2009	860,67	1323,88	36,39	762,42	892,44	4,23
2010	910,44	1156,75	34,01	824,70	944,85	3,74
2011	974,78	1454,92	38,14	875,39	1023,58	3,91
2012	962,82	1525,45	39,06	896,87	1039,88	4,06
2013	952,10	2347,48	48,45	858,51	1047,59	5,09
2014	1007,11	710,00	26,65	935,24	1031,56	2,65
2015	1029,10	1363,46	36,93	941,18	1070,70	3,59
2016	1055,99	1171,33	34,22	1007,57	1104,09	3,24
2017	1063,82	1670,07	40,87	962,34	1111,76	3,84
2018	885,19	11941,71	109,28	796,12	1089,36	12,35
2019	899,36	9152,35	95,67	736,77	1055,86	10,64
2020	991,20	3006,25	54,83	905,45	1064,69	5,53
2021	1080,77	955,63	30,91	1007,06	1126,90	2,86

Na tabela 9.6, é exibido o resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado do Amapá.

Tabela 9.6 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Amapá em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	1,94	0,43	0,65	0,35	3,20	33,81
2005	2,70	0,67	0,82	2,03	4,26	30,37
2006	4,01	0,72	0,85	1,86	5,07	21,23
2007	4,24	0,04	0,20	4,03	4,67	4,76
2008	4,42	0,28	0,53	3,48	5,31	11,90
2009	3,15	0,18	0,42	2,62	4,04	13,38
2010	2,89	0,07	0,26	2,53	3,32	8,84
2011	2,89	0,04	0,19	2,57	3,18	6,62
2012	3,05	0,26	0,51	1,70	3,55	16,78
2013	3,17	0,42	0,65	2,58	4,53	20,46

Continua na próxima página.

Tabela 9.6 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	3,27	0,07	0,26	2,80	3,72	7,91
2015	3,11	0,28	0,53	2,46	4,23	16,94
2016	3,95	0,23	0,47	3,40	5,26	12,02
2017	5,15	1,60	1,27	3,58	6,63	24,60
2018	7,31	1,13	1,06	5,91	9,23	14,55
2019	8,84	0,45	0,67	7,78	9,72	7,59
2020	8,89	1,55	1,24	5,51	10,33	14,01
2021	9,64	0,59	0,77	8,52	11,24	7,96

Na tabela 9.7, é exibido o resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado do Tocantins.

Tabela 9.7 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Tocantins em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	9,25	1,81	1,35	6,55	11,04	14,55
2005	9,02	0,88	0,94	7,70	10,60	10,38
2006	8,70	0,59	0,77	7,66	10,01	8,82
2007	10,44	1,22	1,11	8,20	11,66	10,60
2008	11,72	2,16	1,47	9,25	13,47	12,53
2009	12,88	4,02	2,00	9,62	16,08	15,56
2010	17,15	2,92	1,71	13,02	18,64	9,97
2011	19,37	3,00	1,73	16,06	22,00	8,95
2012	19,84	2,37	1,54	17,73	22,13	7,75
2013	22,96	6,30	2,51	18,92	26,34	10,93
2014	25,73	8,77	2,96	20,95	30,27	11,51
2015	26,39	11,86	3,44	20,42	30,82	13,05
2016	24,17	9,21	3,04	19,00	28,19	12,56
2017	24,63	10,64	3,26	18,46	29,34	13,25
2018	28,72	5,38	2,32	24,60	32,15	8,07
2019	27,04	6,42	2,53	21,62	30,76	9,37
2020	27,15	11,69	3,42	20,65	31,05	12,60
2021	31,18	17,09	4,13	24,40	35,98	13,26

9.2 Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Nordeste

Tabela 9.8 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Alagoas em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	153,50	105,03	10,25	132,54	166,65	6,68
2005	157,73	91,82	9,58	130,78	169,35	6,08
2006	155,49	210,30	14,50	117,83	169,93	9,33
2007	160,61	104,41	10,22	137,27	171,18	6,36
2008	165,44	44,55	6,67	152,70	174,28	4,03
2009	148,15	70,19	8,38	140,24	169,29	5,65
2010	157,99	474,25	21,78	92,43	170,94	13,78
2011	135,61	948,35	30,80	72,07	169,43	22,71
2012	162,09	246,13	15,69	124,97	178,81	9,68
2013	172,75	100,80	10,04	146,73	180,00	5,81
2014	177,30	110,95	10,53	150,82	189,31	5,94
2015	171,31	129,02	11,36	144,97	186,03	6,63
2016	170,12	143,02	11,96	146,41	182,88	7,03
2017	164,25	246,53	15,70	135,33	178,77	9,56
2018	138,95	2158,51	46,46	46,35	179,34	33,44
2019	84,96	1239,93	35,21	53,22	164,01	41,44
2020	60,69	26,05	5,10	47,62	65,77	8,41
2021	113,17	417,48	20,43	78,16	132,65	18,06

Tabela 9.9 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Bahia em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	790,44	987,11	31,42	726,12	833,82	3,97
2005	803,33	1089,29	33,00	736,08	851,20	4,11
2006	798,99	898,61	29,98	720,58	834,81	3,75
2007	854,73	3978,06	63,07	723,73	943,33	7,38
2008	897,47	2893,08	53,79	772,93	988,76	5,99
2009	789,40	2971,97	54,52	711,93	875,60	6,91
2010	861,19	1159,98	34,06	801,95	923,11	3,95
2011	777,84	1777,67	42,16	670,45	829,13	5,42
2012	800,18	1320,20	36,33	721,02	842,31	4,54
2013	825,21	533,80	23,10	776,76	858,84	2,80

Continua na próxima página.

Tabela 9.9 - Continuação da tabela

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	890,33	1985,05	44,55	794,08	940,29	5,00
2015	787,56	2639,07	51,37	701,51	866,49	6,52
2016	719,00	800,05	28,29	650,94	767,24	3,93
2017	747,04	1105,77	33,25	689,50	798,56	4,45
2018	773,46	724,40	26,91	714,27	812,44	3,48
2019	769,16	1791,70	42,33	673,62	831,25	5,50
2020	765,15	2088,48	45,70	694,68	831,95	5,97
2021	790,28	1233,71	35,12	704,56	828,33	4,44

Tabela 9.10 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Ceará em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	155,27	133,83	11,57	135,53	174,61	7,45
2005	162,48	37,18	6,10	154,60	173,89	3,75
2006	160,89	48,13	6,94	152,24	173,15	4,31
2007	169,50	69,05	8,31	157,39	182,46	4,90
2008	170,61	83,77	9,15	153,47	184,99	5,36
2009	172,69	166,37	12,90	156,49	191,00	7,47
2010	185,32	99,95	10,00	165,65	196,16	5,39
2011	192,78	146,44	12,10	167,61	209,89	6,28
2012	198,59	72,78	8,53	183,50	210,56	4,30
2013	208,19	114,91	10,72	194,09	227,20	5,15
2014	204,70	111,71	10,57	187,76	220,29	5,16
2015	200,62	76,92	8,77	176,88	212,37	4,37
2016	224,82	1353,03	36,78	178,47	290,31	16,36
2017	198,61	103,17	10,16	179,62	211,13	5,11
2018	193,43	135,15	11,63	176,85	212,02	6,01
2019	208,66	253,80	15,93	171,26	228,58	7,64
2020	183,72	1879,23	43,35	81,64	235,04	23,60
2021	211,16	170,30	13,05	185,75	228,45	6,18

Tabela 9.11 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Maranhão em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	562,09	295,03	17,18	528,80	599,41	3,06
2005	572,45	936,03	30,59	519,69	648,48	5,34
2006	634,69	965,35	31,07	564,26	672,35	4,90
2007	662,63	503,55	22,44	603,34	685,86	3,39
2008	669,86	341,91	18,49	629,11	691,27	2,76
2009	633,21	785,82	28,03	570,77	669,41	4,43
2010	656,87	501,22	22,39	603,47	682,51	3,41
2011	675,94	803,43	28,34	605,12	715,50	4,19
2012	614,39	646,20	25,42	575,00	655,58	4,14
2013	515,87	3046,61	55,20	423,17	570,46	10,70
2014	291,74	5716,69	75,61	229,62	426,47	25,92
2015	132,79	4927,98	70,20	81,39	263,12	52,87
2016	92,90	122,09	11,05	77,47	106,81	11,89
2017	95,91	147,58	12,15	78,25	114,83	12,67
2018	108,07	171,12	13,08	83,11	123,15	12,10
2019	129,04	157,53	12,55	104,85	144,24	9,73
2020	132,72	207,63	14,41	108,51	158,39	10,86
2021	141,43	354,22	18,82	117,18	161,17	13,31

Tabela 9.12 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio Grande do Norte em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	84,93	41,71	6,46	72,30	94,61	7,60
2005	92,91	28,78	5,37	83,99	99,24	5,77
2006	97,91	41,40	6,43	84,07	105,77	6,57
2007	104,51	11,74	3,43	98,05	109,35	3,28
2008	100,04	11,33	3,37	93,50	104,28	3,36
2009	96,03	31,63	5,62	89,39	104,64	5,86
2010	105,27	32,21	5,68	94,01	112,72	5,39
2011	103,76	16,96	4,12	92,54	108,62	3,97
2012	103,24	20,25	4,50	93,56	111,15	4,36
2013	107,32	21,82	4,67	95,77	112,26	4,35
2014	110,23	9,78	3,13	104,40	114,53	2,84

Continua na próxima página.

Tabela 9.12 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2015	107,45	8,24	2,87	103,35	112,47	2,67
2016	104,07	11,77	3,43	98,66	108,62	3,30
2017	101,37	14,75	3,84	97,55	109,93	3,79
2018	100,62	21,62	4,65	93,48	107,29	4,62
2019	100,11	13,79	3,71	93,94	105,43	3,71
2020	98,79	122,16	11,05	73,66	111,66	11,19
2021	106,24	21,56	4,64	99,18	112,62	4,37

Tabela 9.13 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Sergipe em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	93,81	51,36	7,17	81,79	102,19	7,64
2005	102,78	28,60	5,35	89,06	109,37	5,20
2006	106,28	16,43	4,05	99,34	113,25	3,81
2007	114,08	65,50	8,09	98,54	124,43	7,09
2008	115,09	15,48	3,93	108,32	119,65	3,42
2009	113,88	47,44	6,89	102,96	127,01	6,05
2010	122,62	48,77	6,98	110,41	132,09	5,70
2011	128,81	71,94	8,48	106,64	139,95	6,58
2012	131,05	35,33	5,94	121,03	139,47	4,54
2013	135,79	32,60	5,71	124,61	142,39	4,20
2014	133,00	44,95	6,70	121,32	146,58	5,04
2015	125,37	48,65	6,98	116,95	137,00	5,56
2016	116,69	5,51	2,35	112,12	120,43	2,01
2017	107,98	53,04	7,28	91,69	116,14	6,74
2018	103,96	34,67	5,89	93,39	117,79	5,66
2019	90,28	16,63	4,08	86,06	100,75	4,52
2020	87,08	36,58	6,05	74,19	96,83	6,95
2021	98,72	42,33	6,51	86,93	108,02	6,59

Tabela 9.14 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado da Paraíba em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	84,99	49,99	7,07	70,54	91,93	8,32
2005	90,93	29,90	5,47	77,93	96,31	6,01
2006	95,58	9,29	3,05	88,91	99,52	3,19
2007	103,69	42,47	6,52	88,94	111,39	6,29
2008	106,00	29,72	5,45	97,47	113,60	5,14
2009	103,62	47,33	6,88	91,27	112,22	6,64
2010	116,03	28,18	5,31	105,74	122,44	4,58
2011	110,67	48,92	6,99	101,25	125,51	6,32
2012	117,43	20,87	4,57	109,57	123,40	3,89
2013	121,65	17,70	4,21	114,48	127,15	3,46
2014	122,91	28,23	5,31	113,70	133,92	4,32
2015	122,10	86,75	9,31	108,23	132,85	7,63
2016	121,70	41,41	6,44	110,46	133,49	5,29
2017	120,53	26,42	5,14	110,34	126,31	4,26
2018	120,94	36,23	6,02	111,16	128,44	4,98
2019	120,10	17,43	4,18	113,01	127,99	3,48
2020	116,04	233,54	15,28	88,69	136,19	13,17
2021	120,81	37,29	6,11	112,74	130,96	5,05

Tabela 9.15 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Pernambuco em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	185,52	148,73	12,20	165,83	199,98	6,57
2005	192,60	65,87	8,12	181,72	204,31	4,21
2006	194,68	42,81	6,54	180,49	206,12	3,36
2007	217,65	85,83	9,26	202,68	233,03	4,26
2008	222,72	99,29	9,96	199,40	234,20	4,47
2009	214,45	356,91	18,89	180,86	240,71	8,81
2010	239,41	138,18	11,75	217,01	260,11	4,91
2011	249,15	87,98	9,38	230,34	265,38	3,76
2012	262,57	83,91	9,16	247,80	273,81	3,49
2013	284,49	134,90	11,61	263,80	303,24	4,08
2014	294,92	97,88	9,89	280,60	315,92	3,35

Continua na próxima página.

Tabela 9.15 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2015	316,76	72,31	8,50	300,34	332,82	2,68
2016	320,70	79,00	8,89	301,94	332,36	2,77
2017	311,09	108,05	10,39	297,46	326,86	3,34
2018	304,72	109,18	10,45	289,43	324,16	3,43
2019	309,90	89,48	9,46	297,57	333,97	3,05
2020	299,67	844,89	29,07	233,05	340,74	9,70
2021	331,26	96,65	9,83	313,72	343,81	2,97

Tabela 9.16 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Piauí em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	15,11	2,50	1,58	12,28	17,40	10,46
2005	17,18	1,83	1,35	14,84	19,66	7,88
2006	17,70	2,67	1,63	14,44	20,44	9,24
2007	19,09	3,49	1,87	14,62	21,79	9,78
2008	19,66	2,68	1,64	16,78	22,48	8,33
2009	19,28	6,21	2,49	14,01	24,07	12,92
2010	20,95	1,65	1,29	18,63	23,06	6,13
2011	20,44	3,98	1,99	16,85	23,09	9,76
2012	18,99	7,56	2,75	15,56	24,27	14,49
2013	22,38	3,53	1,88	18,95	24,54	8,39
2014	24,08	4,90	2,21	21,00	26,95	9,19
2015	22,57	1,76	1,33	19,84	24,54	5,87
2016	19,79	2,15	1,47	17,21	21,72	7,41
2017	17,43	1,70	1,31	15,09	19,10	7,49
2018	16,68	4,83	2,20	11,21	18,87	13,18
2019	17,33	3,28	1,81	13,50	19,43	10,45
2020	15,95	8,81	2,97	10,72	20,28	18,61
2021	18,40	3,21	1,79	14,49	20,35	9,73

9.3 Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Centro-Oeste

Na tabela 9.17, é exibido o resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado de Mato Grosso em GWh.

Tabela 9.17 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Mato Grosso em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	94,57	233,71	15,29	61,69	115,33	16,16
2005	96,84	102,48	10,12	72,95	110,09	10,45
2006	98,23	110,15	10,50	77,90	110,57	10,68
2007	115,85	133,82	11,57	88,69	130,25	9,99
2008	126,85	159,59	12,63	99,15	142,44	9,96
2009	134,42	168,91	13,00	107,41	150,22	9,67
2010	135,92	83,25	9,12	120,75	147,23	6,71
2011	154,11	200,39	14,16	124,83	170,17	9,19
2012	166,13	201,62	14,20	131,68	183,57	8,55
2013	182,37	145,33	12,06	158,11	197,02	6,61
2014	185,20	194,38	13,94	156,89	202,66	7,53
2015	170,67	96,39	9,82	153,79	181,46	5,75
2016	159,36	100,09	10,00	141,72	170,04	6,28
2017	166,47	143,60	11,98	147,37	182,89	7,20
2018	173,88	152,26	12,34	151,93	187,71	7,10
2019	181,07	152,95	12,37	162,50	199,03	6,83
2020	190,38	234,60	15,32	162,78	212,56	8,05
2021	190,43	130,02	11,40	165,55	206,24	5,99

Na tabela 9.18, é exibido o resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado de Mato Grosso do Sul em GWh.

Tabela 9.18 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Mato Grosso do Sul em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	72,17	30,64	5,53	63,92	80,59	7,67
2005	74,18	19,43	4,41	65,61	80,62	5,94
2006	73,35	13,49	3,67	65,99	76,75	5,01
2007	78,95	18,47	4,30	69,00	83,47	5,44
2008	86,80	31,30	5,59	76,28	93,77	6,45
2009	80,83	63,76	7,98	68,81	96,94	9,88
2010	83,14	21,93	4,68	74,43	89,13	5,63
2011	87,79	13,05	3,61	80,54	92,53	4,11
2012	96,06	35,96	6,00	84,51	105,87	6,24
2013	112,17	57,55	7,59	100,34	120,88	6,76

Continua na próxima página.

Tabela 9.18 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	103,04	9,78	3,13	95,56	107,33	3,04
2015	96,22	30,76	5,55	89,43	105,29	5,76
2016	90,25	14,56	3,82	80,89	95,30	4,23
2017	95,36	13,94	3,73	87,62	101,69	3,92
2018	104,30	19,21	4,38	96,47	110,80	4,20
2019	112,63	4,71	2,17	109,41	115,80	1,93
2020	121,27	55,77	7,47	105,04	131,90	6,16
2021	128,77	16,33	4,04	120,78	136,27	3,14

Na tabela 9.19 contêm resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado de Goiás.

Tabela 9.19 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Goiás em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	227,17	258,24	16,07	205,13	250,07	7,07
2005	238,29	339,15	18,42	216,37	278,57	7,73
2006	239,13	90,07	9,49	223,60	261,30	3,97
2007	238,45	296,59	17,22	207,05	262,00	7,22
2008	257,04	521,22	22,83	218,76	293,04	8,88
2009	273,33	679,54	26,07	227,09	327,82	9,54
2010	273,45	98,83	9,94	260,68	289,17	3,64
2011	335,76	1673,49	40,91	266,83	389,73	12,18
2012	388,78	486,71	22,06	357,83	423,63	5,67
2013	407,86	877,48	29,62	363,44	444,68	7,26
2014	417,28	568,74	23,85	378,88	459,30	5,72
2015	411,60	855,88	29,26	363,74	470,61	7,11
2016	445,53	219,06	14,80	428,61	478,02	3,32
2017	448,48	324,46	18,01	401,80	466,80	4,02
2018	465,48	1325,63	36,41	395,57	532,98	7,82
2019	467,58	602,23	24,54	422,27	504,84	5,25
2020	480,38	270,59	16,45	452,65	510,33	3,42
2021	491,51	313,65	17,71	458,70	513,18	3,60

Na tabela 9.20 contém resumo estatístico dos dados de consumo de energia elétrica do setor industrial do estado do Distrito Federal.

Tabela 9.20 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Distrito Federal em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	34,43	63,03	7,94	25,61	48,29	23,06
2005	35,96	4,44	2,11	31,38	39,04	5,86
2006	38,18	7,23	2,69	33,87	43,15	7,04
2007	41,51	14,36	3,79	34,15	45,71	9,13
2008	45,81	7,23	2,69	40,22	48,62	5,87
2009	48,36	14,16	3,76	43,37	53,33	7,78
2010	52,86	5,19	2,28	49,58	57,13	4,31
2011	56,28	13,12	3,62	51,02	61,52	6,44
2012	61,07	16,45	4,06	54,40	68,07	6,64
2013	65,33	19,17	4,38	59,45	71,58	6,70
2014	67,07	8,39	2,90	60,68	71,00	4,32
2015	61,09	6,21	2,49	56,62	64,68	4,08
2016	51,10	9,16	3,03	46,03	55,91	5,92
2017	43,90	12,21	3,49	38,90	49,83	7,96
2018	42,69	7,32	2,71	36,47	47,34	6,34
2019	43,53	4,86	2,20	39,63	46,74	5,07
2020	49,37	48,61	6,97	37,81	56,93	14,12
2021	52,98	9,45	3,07	46,17	58,08	5,80

9.4 Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Sudeste

Tabela 9.21 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de São Paulo em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	3902,05	44330,21	210,55	3499,33	4128,93	5,40
2005	3996,09	22490,35	149,97	3691,58	4164,24	3,75
2006	4169,13	16443,54	128,23	3856,96	4300,32	3,08
2007	4454,31	35158,26	187,51	4049,59	4690,14	4,21
2008	4502,74	32295,33	179,71	4159,36	4763,45	3,99
2009	4217,56	70072,56	264,71	3662,82	4574,34	6,28
2010	4565,00	61026,15	247,03	3864,34	4748,77	5,41
2011	4665,77	20909,61	144,60	4325,40	4849,90	3,10
2012	4635,70	18384,95	135,59	4352,53	4840,52	2,92
2013	4629,20	18148,93	134,72	4257,68	4787,64	2,91

Continua na próxima página.

Tabela 9.21 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	4354,48	27896,02	167,02	4052,98	4553,56	3,84
2015	4074,41	16267,85	127,55	3883,53	4323,09	3,13
2016	3875,65	18346,12	135,45	3475,16	3977,94	3,49
2017	3957,05	31859,70	178,49	3561,12	4170,48	4,51
2018	4067,11	15599,87	124,90	3897,66	4235,01	3,07
2019	3969,64	8271,74	90,95	3811,38	4138,19	2,29
2020	3830,02	152801,93	390,90	3104,15	4277,90	10,21
2021	4269,55	12816,35	113,21	4132,19	4518,29	2,65

Tabela 9.22 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Minas Gerais em GWh.

Ano	Média	Variância	Desvio Padrão	Mínimo	Máximo	Co. Variação
2004	2489,66	9209,00	95,96	2346,69	2686,55	3,85
2005	2508,89	7526,61	86,76	2380,81	2634,83	3,46
2006	2447,29	6312,15	79,45	2261,69	2563,76	3,25
2007	2717,54	4669,84	68,34	2576,07	2819,26	2,51
2008	2555,87	26561,55	162,98	2251,14	2735,90	6,38
2009	2188,70	41194,67	202,96	1903,37	2475,10	9,27
2010	2626,25	12843,83	113,33	2421,24	2744,68	4,32
2011	2707,68	4967,43	70,48	2570,55	2796,16	2,60
2012	2598,87	5873,85	76,64	2384,33	2666,97	2,95
2013	2533,67	8199,84	90,55	2392,52	2645,97	3,57
2014	2439,01	6221,91	78,88	2285,82	2572,34	3,23
2015	2345,84	4401,31	66,34	2205,26	2464,84	2,83
2016	2440,29	11028,54	105,02	2207,59	2570,17	4,30
2017	2436,87	4827,42	69,48	2342,68	2539,41	2,85
2018	2583,26	5114,57	71,52	2424,93	2672,36	2,77
2019	2480,80	6269,91	79,18	2353,20	2624,62	3,19
2020	2501,89	22598,28	150,33	2268,05	2728,95	6,01
2021	2704,55	6182,97	78,63	2534,71	2812,80	2,91

Tabela 9.23 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Espírito Santo em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	329,02	94,86	9,74	314,20	344,80	2,96
2005	348,29	176,96	13,30	321,24	366,10	3,82
2006	363,23	182,93	13,53	338,32	389,85	3,72
2007	370,90	133,80	11,57	350,12	388,19	3,12
2008	364,04	2512,81	50,13	230,79	409,83	13,77
2009	294,93	4445,84	66,68	186,94	370,85	22,61
2010	391,14	297,33	17,24	357,98	416,99	4,41
2011	413,46	175,67	13,25	390,28	429,46	3,21
2012	408,25	324,69	18,02	380,95	430,80	4,41
2013	416,27	292,51	17,10	387,58	441,25	4,11
2014	426,51	201,77	14,20	409,74	455,45	3,33
2015	408,39	1490,57	38,61	327,42	442,61	9,45
2016	319,18	231,18	15,20	287,15	339,13	4,76
2017	324,28	196,85	14,03	304,50	359,10	4,33
2018	345,32	497,58	22,31	311,36	373,23	6,46
2019	333,93	444,87	21,09	288,68	351,61	6,32
2020	314,48	717,23	26,78	273,72	349,66	8,52
2021	341,05	763,82	27,64	297,39	391,01	8,10

Tabela 9.24 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio de Janeiro em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	757,77	490,64	22,15	730,57	791,73	2,92
2005	781,51	829,98	28,81	741,96	848,35	3,69
2006	761,72	1788,55	42,29	682,95	841,45	5,55
2007	788,59	984,06	31,37	751,77	862,96	3,98
2008	786,95	1465,89	38,29	688,40	823,29	4,87
2009	676,63	1990,72	44,62	625,84	771,01	6,59
2010	793,09	4579,99	67,68	672,84	886,56	8,53

Continua na próxima página.

Tabela 9.24 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2011	744,81	1048,45	32,38	703,93	826,82	4,35
2012	756,11	891,92	29,87	714,80	798,51	3,95
2013	773,93	569,52	23,86	736,85	813,49	3,08
2014	733,73	383,50	19,58	703,72	763,52	2,67
2015	733,18	1923,47	43,86	632,29	790,65	5,98
2016	699,88	1221,29	34,95	614,80	755,90	4,99
2017	684,13	1030,07	32,09	636,89	751,38	4,69
2018	694,49	1688,29	41,09	602,49	750,96	5,92
2019	667,37	769,46	27,74	613,78	703,19	4,16
2020	670,03	2771,28	52,64	564,96	722,37	7,86
2021	716,37	714,56	26,73	659,50	744,16	3,73

9.5 Resumo Estatístico dos Dados de Consumo de Energia Elétrica do Setor Industrial dos Estados da Região Sul

Tabela 9.25 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Paraná em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	749,50	714,93	26,74	691,43	777,59	3,57
2005	758,10	683,21	26,14	689,45	783,75	3,45
2006	787,80	618,81	24,88	738,26	828,89	3,16
2007	819,73	1637,23	40,46	721,49	869,37	4,94
2008	873,03	1206,76	34,74	804,42	906,02	3,98
2009	830,60	2968,76	54,49	720,14	880,35	6,56
2010	887,46	910,73	30,18	798,37	908,32	3,40
2011	921,53	1001,35	31,64	839,66	954,82	3,43
2012	946,35	1323,12	36,37	854,11	990,80	3,84
2013	989,93	2815,31	53,06	850,92	1043,14	5,36
2014	1009,00	2338,93	48,36	898,54	1066,84	4,79
2015	988,97	990,80	31,48	917,55	1031,57	3,18
2016	996,09	2161,24	46,49	869,19	1056,40	4,67
2017	1033,48	1756,19	41,91	937,67	1110,88	4,05
2018	1060,43	2029,88	45,05	976,19	1113,57	4,25
2019	1073,58	1032,62	32,13	1024,38	1121,06	2,99
2020	1067,94	5921,85	76,95	919,66	1169,53	7,21
2021	1157,62	1222,50	34,96	1087,91	1204,57	3,02

Tabela 9.26 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado de Santa Catarina em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	581,40	1641,86	40,52	466,79	623,12	6,97
2005	598,75	974,82	31,22	510,63	631,14	5,21
2006	616,51	985,77	31,40	530,11	645,61	5,09
2007	664,60	1594,52	39,93	562,29	713,18	6,01
2008	697,92	2691,04	51,88	577,04	743,47	7,43
2009	662,92	2111,60	45,95	528,77	706,24	6,93
2010	729,96	2363,50	48,62	588,38	776,97	6,66
2011	747,40	1269,96	35,64	646,51	783,24	4,77
2012	775,99	2005,19	44,78	651,00	823,18	5,77
2013	815,86	1621,04	40,26	719,07	873,08	4,93
2014	832,18	1201,93	34,67	754,36	878,39	4,17
2015	788,95	1699,26	41,22	716,25	844,24	5,22
2016	788,82	1439,55	37,94	682,92	831,33	4,81
2017	832,64	1168,08	34,18	753,64	877,20	4,10
2018	854,30	1329,26	36,46	793,00	895,57	4,27
2019	884,49	1302,97	36,10	812,40	933,19	4,08
2020	882,11	7688,11	87,68	728,48	992,38	9,94
2021	967,52	1651,58	40,64	882,69	1029,94	4,20

Tabela 9.27 – Tabela de medidas estatísticas para os dados de consumo de energia elétrica do setor industrial do estado do Rio Grande do Sul em GWh.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2004	757,60	6986,24	83,58	640,58	845,67	11,03
2005	740,82	964,09	31,05	666,85	784,53	4,19
2006	754,50	1418,03	37,66	647,57	794,41	4,99
2007	797,37	1485,91	38,55	689,79	828,03	4,83
2008	822,82	2858,57	53,47	708,36	881,78	6,50
2009	753,41	5291,87	72,75	568,86	823,42	9,66
2010	847,22	2257,85	47,52	717,07	891,31	5,61
2011	882,90	1740,04	41,71	777,39	925,69	4,72
2012	854,02	2409,88	49,09	746,66	908,03	5,75
2013	888,76	3378,97	58,13	730,71	954,10	6,54

Continua na próxima página.

Tabela 9.27 - Continuação da tabela.

Ano	Média	Variância	Desvio padrão	Mínimo	Máximo	Co. Variação
2014	872,90	1389,79	37,28	769,80	903,06	4,27
2015	823,91	2216,34	47,08	728,98	908,48	5,71
2016	790,89	2151,56	46,38	661,12	836,23	5,86
2017	822,05	2441,86	49,42	687,17	865,83	6,01
2018	817,33	2490,66	49,91	719,00	892,34	6,11
2019	813,88	987,78	31,43	744,67	848,97	3,86
2020	783,11	4987,45	70,62	661,81	877,89	9,02
2021	866,63	1634,13	40,42	809,18	956,84	4,66

9.6 Previsão para a Hierarquia Brasil-Regiões-Estados

Tabela 9.28 – Previsão do consumo de energia elétrica do setor industrial Brasileiro utilizando a abordagem híbrida com o método preditivo de suavização exponencial para 24 meses (GWh).

Mês	Previsão	Cenário Mínimo	Cenário Máximo
Jan/22	14394,77	14388,73	14401,80
Fev/22	14722,98	14717,61	14725,11
Mar/22	15204,63	15200,05	15217,66
Abr/22	15186,75	15174,95	15187,37
Mai/22	15078,29	15075,10	15083,61
Jun/22	15065,78	15054,88	15072,53
Jul/22	15289,07	15289,23	15310,33
Ago/22	15621,56	15612,41	15636,09
Set/22	15484,25	15476,02	15497,38
Out/22	15600,35	15579,19	15608,31
Nov/22	15486,25	15478,64	15504,50
Dez/22	15137,73	15124,24	15147,19
Jan/23	14452,20	14439,10	14474,47
Fev/23	14780,15	14767,78	14797,53
Mar/23	15272,55	15250,02	15289,83
Abr/23	15240,19	15224,73	15259,31
Mai/23	15137,55	15124,70	15155,32
Jun/23	15134,98	15104,30	15144,03
Jul/23	15360,72	15338,48	15381,62
Ago/23	15667,36	15661,50	15707,18
Set/23	15541,54	15524,95	15568,28
Out/23	15669,35	15627,98	15679,03
Nov/23	15557,18	15527,27	15575,05
Dez/23	15200,30	15172,73	15217,57

Tabela 9.29 – Previsão do consumo de energia elétrica do setor industrial Brasileiro utilizando a abordagem híbrida com o método preditivo de Box e Jenkins para 24 meses (GWh).

Mês	Previsão	Cenário Mínimo	Cenário Máximo
Jan/22	14789,97	14764,24	14805,98
Fev/22	14862,60	14832,45	14875,47
Mar/22	15376,64	15370,63	15378,30
Abr/22	15024,81	14998,27	15041,57
Mai/22	14909,91	14862,68	14906,76
Jun/22	14829,94	14816,58	14835,31
Jul/22	15121,88	15119,79	15125,09
Ago/22	15325,46	15323,61	15333,23
Set/22	15193,88	15192,48	15209,08
Out/22	15411,54	15399,67	15421,35
Nov/22	15250,42	15248,80	15269,79
Dez/22	14926,61	14898,15	14936,94
Jan/23	14575,17	14543,51	14632,71
Fev/23	14710,86	14694,90	14776,27
Mar/23	15171,51	15166,60	15240,14
Abr/23	14895,92	14877,25	14932,24
Mai/23	14747,25	14742,75	14790,19
Jun/23	14718,02	14679,01	14744,47
Jul/23	14983,24	14980,16	15035,73
Ago/23	15222,33	15218,50	15259,99
Set/23	15140,37	15096,56	15157,55
Out/23	15285,03	15273,81	15337,13
Nov/23	15161,71	15159,12	15234,00
Dez/23	14847,81	14805,49	14897,69

Nas figuras 9.1 e 9.2 observam-se as comparações das previsões de todas as quatro abordagens do consumo de energia elétrica do setor industrial brasileiro com o método de suavização exponencial e de Box e Jenkins, respectivamente. Veja que o comportamento das previsões das abordagens pelo método de suavização exponencial tem um comportamento parecido.

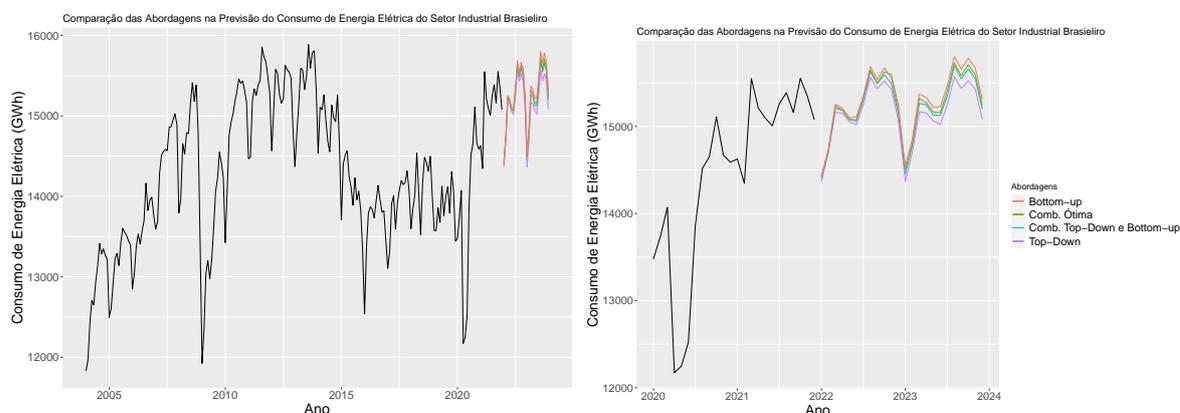


Figura 9.1 – Comparação das previsões das duas quatro abordagens para a hierarquia de dois níveis do consumo de energia elétrica do setor industrial brasileiro utilizando o método preditivo de suavização exponencial.

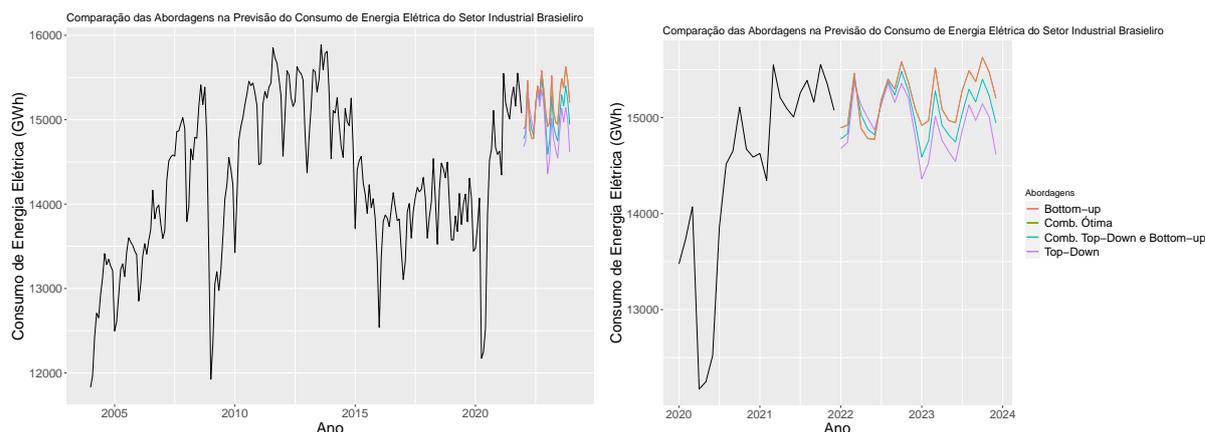


Figura 9.2 – Comparação das previsões das duas quatro abordagens para a hierarquia de dois níveis do consumo de energia elétrica do setor industrial brasileiro utilizando o método preditivo de Box e Jenkins.

9.7 Hierarquia Regiões-Estados

Nesta subseção, será apresentado as análises e previsões para a hierarquia de dois níveis contendo a série de consumo de energia elétrica do setor industrial de cada região brasileira.

Nas tabelas 9.30 e 9.31 observam-se as métricas MAPE e RMSE das abordagens *top-down*, *bottom-up*, combinação ótima e combinação *top-down* e *bottom-up* para os cinco cenários de conjuntos de teste, sendo a primeira foi usada o método preditivo de suavização exponencial e a segunda o método de Box e Jenkins.

Tabela 9.30 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Norte e seus estados utilizando o método de suavização exponencial.

Bottom-up	2017		2018		2019	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,85%	29,20	18,11%	216,02	6,99%	100,68
Acre	10,67%	0,42	10,96%	0,38	9,66%	0,34
Amapá	27,37%	1,89	12,97%	1,36	7,67%	0,85
Amazonas	4,85%	9,22	4,57%	7,38	3,88%	6,82
Pará	2,68%	33,74	23,33%	222,07	8,41%	99,84
Rondônia	6,61%	2,66	4,66%	2,15	2,86%	1,28
Roraima	10,59%	0,25	14,81%	0,45	27,48%	0,54
Tocantins	11,00%	3,52	8,79%	2,82	13,22%	4,06

Continua na próxima página

Tabela 9.30 - Continuação da tabela

	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	4,77%	75,24	3,66%	56,38	7,08%	95,50
Acre	5,04%	0,21	7,49%	0,35	8,76%	0,34
Amapá	11,49%	1,35	27,08%	2,74	17,32%	1,64
Amazonas	11,12%	18,25	5,20%	8,50	5,92%	10,03
Pará	5,64%	67,43	3,83%	47,79	8,78%	94,17
Rondônia	7,03%	3,43	9,55%	4,30	6,14%	2,76
Roraima	13,58%	0,29	5,74%	0,12	14,44%	0,33
Tocantins	7,60%	2,41	11,78%	4,32	10,48%	3,43
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,54%	22,60	19,30%	232,93	18,42%	253,87
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	4,57%	70,46	3,69%	56,93	7,24%	97,41
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,76%	26,45	18,24%	217,68	7,28%	105,70
Acre	10,69%	0,42	10,97%	0,38	9,67%	0,34
Amapá	27,41%	1,89	12,96%	1,36	7,69%	0,85
Amazonas	4,73%	9,11	4,61%	7,37	4,21%	7,20
Pará	2,55%	31,66	23,46%	223,46	8,72%	104,28
Rondônia	6,57%	2,65	4,64%	2,13	2,83%	1,27
Roraima	10,59%	0,25	14,81%	0,45	27,46%	0,54
Tocantins	11,03%	3,52	8,77%	2,82	13,18%	4,05
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	4,68%	73,45	3,59%	55,55	7,11%	95,77
Acre	5,04%	0,22	7,49%	0,35	8,77%	0,34
Amapá	11,49%	1,35	27,07%	2,74	17,32%	1,64
Amazonas	11,20%	18,23	5,16%	8,45	5,98%	10,07
Pará	5,49%	65,53	3,76%	47,05	8,80%	94,40
Rondônia	7,10%	3,47	9,58%	4,31	6,14%	2,77
Roraima	13,58%	0,30	5,75%	0,12	14,44%	0,33
Tocantins	7,60%	2,42	11,78%	4,32	10,47%	3,43

Continua na próxima página.

Tabela 9.30 - Continuação da tabela.

	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,47%	22,25	18,28%	218,40	7,39%	105,83
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	4,67%	73,11	3,68%	56,69	7,10%	95,26

Tabela 9.31 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Norte e seus estados utilizando o método de Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,79%	27,51	19,04%	229,17	18,10%	250,82
Acre	11,21%	0,43	14,04%	0,46	9,62%	0,35
Amapá	27,22%	2,03	8,73%	1,00	3,83%	0,43
Amazonas	11,30%	17,37	4,42%	7,01	3,96%	6,06
Pará	2,11%	28,08	24,29%	232,03	22,11%	249,44
Rondônia	6,45%	2,66	5,07%	2,28	3,05%	1,34
Roraima	8,93%	0,21	15,03%	0,47	30,99%	0,60
Tocantins	7,44%	2,46	5,19%	1,67	13,70%	4,22
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	9,04%	119,10	3,47%	66,71	10,29%	138,66
Acre	5,32%	0,21	9,45%	0,39	9,93%	0,37
Amapá	16,51%	1,71	31,03%	3,12	17,46%	1,66
Amazonas	10,90%	18,50	6,27%	11,39	7,37%	12,07
Pará	10,80%	117,42	4,15%	59,89	12,69%	137,37
Rondônia	6,40%	2,92	11,87%	5,02	6,57%	2,84
Roraima	19,92%	0,43	6,71%	0,14	16,32%	0,37
Tocantins	5,55%	1,75	8,28%	2,99	8,03%	2,62
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	2,40%	35,32	17,35%	208,73	18,42%	253,87
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	8,17%	107,03	5,99%	97,78	10,47%	140,55

Continua na próxima página.

Tabela 9.31 - Continuação da tabela.

	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,74%	27,68	19,37%	233,59	17,90%	248,29
Acre	11,20%	0,43	14,06%	0,46	9,62%	0,35
Amapá	27,19%	2,02	8,71%	1,00	3,83%	0,43
Amazonas	10,81%	16,61	4,32%	6,85	3,86%	5,92
Pará	2,57%	32,53	24,70%	235,81	21,84%	247,10
Rondônia	6,15%	2,54	5,12%	2,28	3,03%	1,33
Roraima	8,95%	0,21	15,03%	0,47	31,00%	0,60
Tocantins	7,38%	2,43	5,15%	1,66	13,71%	4,22
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	8,42%	111,31	4,31%	79,29	10,35%	140,03
Acre	5,33%	0,21	9,45%	0,39	9,93%	0,37
Amapá	16,49%	1,71	31,10%	3,13	17,46%	1,66
Amazonas	11,08%	18,59	7,00%	12,18	7,41%	12,03
Pará	10,07%	109,52	4,91%	70,28	13,02%	139,05
Rondônia	6,51%	2,99	11,32%	4,88	6,43%	2,80
Roraima	19,94%	0,43	6,70%	0,14	16,32%	0,37
Tocantins	5,56%	1,75	8,39%	3,02	8,04%	2,62
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	1,68%	23,66	18,21%	219,33	18,32%	252,37
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Norte	8,63%	113,41	4,45%	80,22	10,26%	137,80

Observe que a abordagem *bottom-up* se destacou via suavização exponencial, apresentando o menor MAPE médio, todavia, o menor RMSE médio é da abordagem híbrida. Para o método de Box e Jenkins a abordagem híbrida se destacou em ambas as métricas.

As tabelas 9.32 e 9.33 pode-se observar as métricas MAPE e RMSE dos cinco cenários de conjunto teste para os dados de consumo de energia elétrica do setor industrial da região Nordeste para o método de suavização exponencial e de Box e Jenkins respectivamente.

Tabela 9.32 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados utilizando o método de suavização exponencial.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	3,50%	74,05	2,54%	53,57	5,53%	116,71
Alagoas	8,03%	16,34	50,38%	54,83	117,65%	84,97
Bahia	4,37%	37,37	5,12%	43,72	4,57%	47,67
Ceará	2,96%	6,92	4,86%	11,36	6,46%	19,08
Maranhão	67,68%	70,85	15,71%	18,93	15,88%	24,45
Paraíba	2,78%	4,18	3,29%	5,12	6,67%	5,00
Pernambuco	5,18%	18,32	1,55%	5,28	3,59%	13,19
Piauí	15,22%	2,75	8,34%	2,00	18,48%	3,59
Rio Gr. do Norte	2,88%	3,97	2,77%	3,69	3,45%	3,88
Sergipe	7,20%	10,11	6,73%	7,81	10,49%	10,19
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,80%	149,24	5,33%	106,95	4,74%	100,10
Alagoas	9,60%	7,96	43,66%	54,41	45,86%	43,70
Bahia	5,55%	51,63	3,93%	37,44	4,71%	43,57
Ceará	35,90%	61,99	3,53%	8,97	10,74%	21,66
Maranhão	10,61%	15,53	11,70%	19,60	24,32%	29,87
Paraíba	10,77%	14,29	8,96%	11,31	6,49%	7,98
Pernambuco	7,01%	29,39	5,37%	20,44	4,54%	17,32
Piauí	14,68%	2,56	5,44%	1,23	12,43%	2,43
Rio Gr. do Norte	8,01%	8,98	4,16%	5,39	4,25%	5,18
Sergipe	5,62%	6,29	10,59%	11,94	8,13%	9,27
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	3,94%	81,62	2,67%	59,40	5,59%	117,57
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,56%	135,72	5,75%	114,29	4,90%	101,72
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	3,46%	73,41	2,46%	52,83	5,30%	112,27
Alagoas	8,07%	16,43	50,84%	55,27	116,48%	84,12
Bahia	4,33%	36,90	4,76%	40,76	4,49%	46,28
Ceará	2,93%	6,88	4,82%	11,29	6,52%	19,20
Maranhão	67,40%	70,70	14,92%	18,03	16,50%	25,45
Paraíba	2,77%	4,18	3,30%	5,13	3,65%	4,98
Pernambuco	5,19%	18,33	1,59%	5,40	3,56%	13,06
Piauí	15,23%	2,76	8,33%	2,00	18,52%	3,60
Rio Gr. do Norte	2,88%	3,97	2,77%	3,67	3,42%	3,86

Continua na próxima página

Tabela 9.32 - Continuação da tabela.

	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,80%	149,21	5,52%	110,27	4,71%	99,60
Alagoas	9,53%	7,90	44,14%	54,89	45,81%	43,72
Bahia	5,53%	51,44	3,91%	37,56	4,60%	42,59
Ceará	35,91%	62,00	3,64%	9,21	10,76%	21,72
Maranhão	10,65%	15,61	12,10%	20,27	24,31%	30,01
Paraíba	10,77%	14,29	8,92%	11,27	5,88%	7,97
Pernambuco	7,01%	29,40	5,42%	20,54	4,55%	17,35
Piauí	14,68%	2,56	5,45%	1,23	12,44%	2,43
Rio Gr. do Norte	8,01%	8,97	4,19%	5,41	4,25%	5,18
Sergipe	5,62%	6,29	10,64%	11,98	8,13%	9,28
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	1,64%	42,37	2,61%	58,37	6,06%	127,13
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,39%	136,83	5,54%	110,55	4,45%	95,05

Tabela 9.33 – Tabela das métricas MAPE e RMSE de cada abordagem hierárquica para os dados de consumo de energia elétrica do setor industrial da região Nordeste e seus estados utilizando o método de Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	3,36%	70,76	4,07%	90,49	5,39%	114,07
Alagoas	7,71%	17,31	50,59%	55,17	112,40%	81,01
Bahia	4,44%	41,91	3,58%	31,54	5,48%	52,31
Ceará	8,98%	22,33	3,97%	8,98	8,26%	21,60
Maranhão	60,88%	69,08	53,87%	63,48	7,89%	11,36
Paraíba	3,78%	5,60	4,78%	6,72	3,65%	4,99
Pernambuco	7,66%	25,22	2,70%	12,31	1,93%	6,67
Piauí	16,11%	2,96	9,89%	2,05	20,85%	4,02
Rio Gr. do Norte	2,92%	3,47	3,99%	4,83	3,85%	4,40
Sergipe	7,01%	9,09	6,04%	7,26	9,83%	9,39

Continua na próxima página.

Tabela 9.33 - Continuação da tabela

	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	8,81%	190,52	7,65%	155,44	5,86%	124,26
Alagoas	85,02%	53,41	40,77%	52,29	59,30%	51,84
Bahia	5,67%	50,49	3,02%	29,15	4,44%	41,08
Ceará	36,60%	62,91	12,05%	27,13	13,97%	28,59
Maranhão	10,33%	15,10	8,33%	13,93	28,26%	34,59
Paraíba	10,28%	14,69	4,11%	5,34	5,32%	7,47
Pernambuco	6,91%	28,19	9,57%	35,89	5,75%	21,66
Piauí	21,89%	3,73	5,85%	1,35	14,92%	2,82
Rio Gr. do Norte	7,55%	8,90	6,37%	7,67	4,94%	5,85
Sergipe	5,46%	5,55	12,53%	14,17	8,17%	9,09
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	3,06%	66,46	4,88%	99,35	4,81%	100,72
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,45%	136,70	8,76%	181,45	5,59%	116,94
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	2,96%	60,72	2,42%	64,69	4,89%	104,90
Alagoas	7,44%	16,26	48,35%	53,50	109,96%	79,35
Bahia	4,69%	42,33	6,23%	53,80	4,69%	48,84
Ceará	8,82%	22,06	3,69%	8,29	8,47%	22,15
Maranhão	62,57%	68,68	45,14%	53,72	9,55%	13,87
Paraíba	3,78%	5,51	4,53%	6,47	3,54%	4,87
Pernambuco	7,61%	25,01	2,98%	13,31	1,86%	6,49
Piauí	16,07%	2,95	9,92%	2,04	20,97%	4,04
Rio Gr. do Norte	2,94%	3,50	4,06%	4,98	3,78%	4,29
Sergipe	6,94%	9,07	5,71%	6,81	9,62%	9,20
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	7,52%	166,92	7,64%	156,31	5,09%	110,71
Alagoas	75,21%	47,57	40,67%	52,42	56,33%	49,82
Bahia	5,79%	52,35	3,01%	29,31	4,88%	45,33
Ceará	35,62%	61,52	12,09%	27,25	13,74%	28,25
Maranhão	7,98%	11,46	8,16%	13,92	26,68%	32,33
Paraíba	10,30%	14,52	4,14%	5,36	5,26%	7,35
Pernambuco	6,77%	27,80	9,57%	35,90	5,76%	21,70
Piauí	21,65%	3,70	5,87%	1,36	14,90%	2,82
Rio Gr. do Norte	7,62%	8,93	6,37%	7,68	4,95%	5,88
Sergipe	5,56%	5,73	12,55%	14,18	8,08%	9,00

Continua na próxima página.

Tabela 9.33 - Continuação da tabela.

	2020		2021		Média	
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	2,72%	58,13	2,90%	70,41	5,49%	116,64
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Nordeste	6,63%	149,22	8,19%	168,13	5,10%	112,51

Na região Nordeste a abordagem que se destacou positivamente para o método de suavização exponencial foi a híbrida e em segundo a combinação ótima. Já para o método preditivo de Box e Jenkins, ocorreu o contrário, a melhor abordagem foi a combinação ótima seguido pela combinação híbrida com uma diferença média de MAPE de 1%.

Nas tabelas 9.34 e 9.35 pode-se observar as métricas MAPE e RMSE dos cinco cenários de conjunto teste para a hierarquia da região Centro-Oeste para o consumo de energia elétrica do setor industrial da região Centro-Oeste.

Tabela 9.34 – Tabela das métricas MAPE e RMSE para os dados da Região Centro-Oeste e seus estados utilizando o método de suavização exponencial.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	3,49%	28,70	2,87%	29,86	2,57%	28,89
Distrito Federal	6,72%	3,44	7,95%	4,06	13,65%	6,38
Goiás	1,50%	10,03	3,94%	24,50	7,00%	35,46
Mato Grosso	11,40%	20,36	2,09%	4,67	3,10%	6,74
Mato Grosso do Sul	7,07%	7,31	5,01%	6,76	4,41%	5,94
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	2,21%	23,86	1,83%	18,58	2,59%	25,98
Distrito Federal	13,24%	8,23	3,62%	2,35	9,04%	4,89
Goiás	1,67%	9,88	1,82%	9,66	3,19%	17,91
Mato Grosso	2,83%	7,12	5,02%	10,07	4,89%	9,79
Mato Grosso do Sul	6,88%	9,40	2,33%	3,29	5,14%	6,54
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	1,80%	16,33	2,05%	19,91	2,26%	21,31
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	3,69%	34,84	2,21%	22,12	2,40%	22,90

Continua na próxima página

Tabela 9.34 - Continuação da tabela

	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	2,90%	23,63	2,72%	28,81	2,70%	29,68
Distrito Federal	6,75%	3,46	7,89%	4,03	13,58%	6,35
Goiás	1,63%	10,49	3,92%	24,08	7,22%	36,41
Mato Grosso	11,20%	20,00	2,07%	4,61	3,10%	6,71
Mato Grosso do Sul	6,85%	7,13	4,93%	6,68	4,35%	5,89
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	2,15%	23,56	1,82%	18,64	2,46%	24,86
Distrito Federal	13,22%	8,21	3,62%	2,35	9,01%	4,88
Goiás	1,73%	10,15	1,83%	9,75	3,27%	18,18
Mato Grosso	2,83%	7,11	5,02%	10,07	4,84%	9,70
Mato Grosso do Sul	6,87%	9,38	2,33%	3,29	5,01%	6,47
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	1,67%	14,92	1,68%	17,18	2,98%	31,34
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	3,15%	31,20	2,03%	20,34	2,30%	23,00

Tabela 9.35 – Tabela das métricas MAPE e RMSE para os dados da Região Centro-Oeste e seus estados utilizando o método de Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	4,57%	37,79	4,06%	41,82	2,92%	31,17
Distrito Federal	8,05%	3,83	4,87%	2,60	8,81%	4,42
Goiás	4,13%	21,08	5,59%	34,54	7,01%	36,63
Mato Grosso	7,90%	14,41	2,27%	4,97	2,87%	6,37
Mato Grosso do Sul	6,27%	6,60	4,41%	5,92	4,43%	5,50
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	3,52%	34,85	1,47%	18,96	3,31%	32,92
Distrito Federal	12,94%	7,79	4,78%	3,15	7,89%	4,36
Goiás	3,05%	17,43	3,01%	16,13	4,56%	25,16
Mato Grosso	2,64%	6,69	4,79%	10,28	4,09%	8,54
Mato Grosso do Sul	5,68%	8,11	2,81%	4,38	4,72%	6,10
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	5,15%	41,81	3,10%	26,39	2,02%	21,74

Continua na próxima página.

Tabela 9.35 - Continuação da tabela

	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	4,22%	39,31	2,62%	26,43	3,42%	31,14
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	2,53%	20,52	3,70%	37,18	2,84%	29,88
Distrito Federal	8,02%	3,93	4,71%	2,52	8,84%	4,41
Goiás	1,87%	11,99	5,20%	30,90	6,97%	35,82
Mato Grosso	7,32%	13,39	2,15%	4,83	2,76%	6,25
Mato Grosso do Sul	5,43%	5,84	4,19%	5,67	4,43%	5,59
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	2,87%	26,93	1,61%	17,74	2,71%	26,45
Distrito Federal	12,57%	7,56	4,82%	3,17	7,79%	4,32
Goiás	2,13%	13,26	1,71%	10,30	3,58%	20,45
Mato Grosso	2,45%	6,30	4,92%	10,58	3,92%	8,27
Mato Grosso do Sul	5,48%	7,80	2,96%	4,50	4,50%	5,88
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	3,77%	29,54	2,52%	24,26	3,57%	33,10
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Centro-Oeste	4,00%	38,34	1,88%	20,73	3,15%	29,19

Na região Centro-Oeste a abordagem que apresentou menor MAPE médio foi a híbrida, já para o RMSE médio a abordagem *top-down*, via suavização exponencial. Para o modelo de Box e Jenkins apresentou menor MAPE e RMSE médios a abordagem de combinação ótima.

Nas tabelas 9.36 e 9.37 pode-se observar as métricas MAPE e RMSE dos cinco cenários de conjunto teste para a hierarquia da região Sudeste para os dados de consumo de energia elétrica do setor industrial.

Tabela 9.36 – Tabela das métricas MAPE e RMSE para os dados da Região Sudeste e seus estados utilizando o método de suavização exponencial.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	3,02%	259,00	2,13%	217,69	2,74%	243,58
Espírito Santo	3,64%	13,97	4,62%	21,14	11,77%	43,07
Minas Gerais	2,45%	68,31	3,38%	114,79	5,05%	142,25
Rio de Janeiro	6,64%	54,58	4,99%	41,56	4,67%	38,30
São Paulo	3,68%	176,25	2,30%	114,12	2,15%	109,08
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	6,93%	542,13	2,45%	251,73	3,45%	302,83
Espírito Santo	7,41%	28,22	4,71%	19,77	6,43%	25,23
Minas Gerais	6,32%	178,51	3,33%	109,49	4,11%	122,67
Rio de Janeiro	7,47%	54,56	2,75%	22,74	5,30%	42,35
São Paulo	8,08%	354,86	2,52%	151,90	3,75%	181,24
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	3,86%	311,50	1,48%	143,54	5,23%	438,75
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	7,70%	572,67	3,22%	309,40	4,30%	355,17
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	2,84%	244,41	2,11%	212,44	2,68%	240,74
Espírito Santo	3,63%	13,87	4,57%	20,98	11,71%	42,90
Minas Gerais	2,41%	68,10	3,22%	110,13	4,97%	139,55
Rio de Janeiro	6,52%	53,82	5,03%	41,72	4,72%	38,77
São Paulo	3,50%	168,25	2,33%	114,69	2,14%	110,22
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	6,98%	544,22	2,32%	243,91	3,39%	297,14
Espírito Santo	7,45%	28,33	4,72%	19,75	6,42%	25,17
Minas Gerais	6,43%	181,04	3,21%	106,38	4,05%	121,04
Rio de Janeiro	7,51%	54,79	2,75%	22,68	5,31%	42,36
São Paulo	8,11%	354,45	2,41%	148,16	3,70%	179,15
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	3,34%	275,50	1,47%	140,77	3,90%	340,31
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	7,12%	535,35	2,82%	278,42	3,73%	314,07

Tabela 9.37 – Tabela das métricas MAPE e RMSE para os dados da Região Sudeste e seus estados utilizando o método de Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	2,64%	232,34	2,34%	216,26	1,91%	179,39
Espírito Santo	5,06%	21,34	6,94%	28,04	10,53%	40,16
Minas Gerais	2,38%	65,20	3,59%	108,84	3,28%	97,43
Rio de Janeiro	5,63%	50,51	5,65%	47,58	4,80%	37,71
São Paulo	3,50%	166,11	2,22%	108,74	2,04%	105,70
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	6,79%	551,41	4,95%	428,89	3,73%	321,66
Espírito Santo	10,45%	42,35	6,33%	26,37	7,86%	31,65
Minas Gerais	4,77%	135,34	5,32%	156,15	3,87%	112,59
Rio de Janeiro	8,65%	61,39	3,29%	30,35	5,60%	45,51
São Paulo	8,14%	355,87	5,95%	277,40	4,37%	202,76
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	4,04%	331,06	1,39%	127,11	4,71%	393,85
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	7,22%	547,71	2,92%	307,09	4,06%	341,36
	2017		2018		2019	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	2,72%	241,78	2,22%	202,81	2,10%	190,46
Espírito Santo	5,12%	21,39	6,76%	27,32	10,71%	40,71
Minas Gerais	2,33%	63,99	3,01%	95,35	3,76%	105,10
Rio de Janeiro	5,74%	51,19	5,88%	48,95	4,60%	36,47
São Paulo	3,64%	170,49	2,28%	107,93	2,14%	106,47
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	6,56%	539,05	3,80%	348,84	3,48%	304,59
Espírito Santo	10,29%	41,74	6,17%	25,62	7,81%	31,36
Minas Gerais	4,42%	127,11	4,10%	119,08	3,52%	102,13
Rio de Janeiro	8,51%	60,48	3,69%	34,27	5,68%	46,27
São Paulo	8,00%	353,03	4,55%	236,84	4,12%	194,95
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	3,17%	268,36	1,40%	129,23	3,11%	274,02
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sudeste	6,82%	528,69	3,34%	329,56	3,57%	305,97

Na região Sudeste a abordagem de combinação ótima apresentou a melhor capacidade preditiva em ambas as métricas via suavização exponencial. O mesmo ocorreu para o método de Box e Jenkins.

Nas tabelas 9.38 e 9.39 pode-se observar as métricas MAPE e RMSE dos cinco cenários de conjunto teste para os dados de consumo de energia elétrica do setor industrial da região Sul.

Tabela 9.38 – Tabela das métricas MAPE e RMSE para os dados da Região Sul e seus estados utilizando o método de suavização exponencial.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	3,37%	95,73	3,00%	90,12	2,51%	82,32
Paraná	2,72%	34,78	3,48%	43,61	2,94%	38,34
Rio Gr. do Sul	3,65%	34,71	4,04%	39,23	5,38%	48,07
Santa Catarina	4,12%	37,40	2,42%	23,91	3,05%	30,61
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,57%	217,89	1,85%	71,94	3,46%	111,60
Paraná	4,92%	70,01	2,88%	39,56	3,39%	45,26
Rio Gr. do Sul	7,38%	76,05	3,83%	43,99	4,86%	48,41
Santa Catarina	8,59%	84,54	1,77%	21,48	3,99%	39,59
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	3,65%	103,12	1,93%	80,96	1,63%	57,91
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,58%	215,92	1,69%	64,65	3,10%	104,51
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	3,18%	91,14	2,95%	87,89	2,57%	84,14
Paraná	2,60%	33,82	3,38%	42,10	2,94%	38,31
Rio Gr. do Sul	3,35%	32,48	4,00%	39,70	5,50%	49,08
Santa Catarina	4,00%	36,50	2,38%	23,71	3,08%	30,95
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,55%	216,67	1,72%	68,63	3,39%	109,69
Paraná	5,01%	69,89	2,83%	38,71	3,35%	44,57
Rio Gr. do Sul	7,36%	74,84	3,53%	41,98	4,75%	47,62
Santa Catarina	8,60%	84,43	1,82%	22,39	3,98%	39,59

Continua na próxima página.

Tabela 9.38 - Continuação da tabela.

	2017		2018		2019	
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	3,49%	99,05	1,96%	79,21	1,71%	58,52
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,67%	219,62	1,73%	67,62	3,11%	104,80

Tabela 9.39 – Tabela das métricas MAPE e RMSE para os dados da Região Sul e seus estados utilizando o método Box e Jenkins.

	2017		2018		2019	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	2,43%	73,10	3,21%	94,35	1,99%	72,92
Paraná	1,60%	20,76	3,48%	41,82	3,44%	40,55
Rio Gr. do Sul	2,85%	27,47	4,59%	42,69	3,88%	39,20
Santa Catarina	4,37%	39,41	2,14%	21,72	2,16%	22,84
	2020		2021		Média	
Bottom-up	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,65%	224,64	3,09%	127,06	3,47%	118,41
Paraná	5,17%	74,66	2,98%	38,93	3,33%	43,34
Rio Gr. do Sul	7,47%	76,51	5,97%	63,11	4,95%	49,80
Santa Catarina	8,12%	84,03	4,63%	53,61	4,28%	44,32
	2017		2018		2019	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	4,29%	119,44	2,04%	76,31	2,21%	73,08
	2020		2021		Média	
Top-Down	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,63%	218,32	4,84%	185,05	4,00%	134,44
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	2,17%	66,70	3,19%	93,19	1,95%	71,91
Paraná	1,60%	20,01	3,41%	41,02	3,38%	39,92
Rio Gr. do Sul	2,44%	24,49	4,55%	42,87	4,02%	39,74
Santa Catarina	4,18%	38,08	2,07%	21,65	2,11%	22,55
	2020		2021		Média	
Comb. Ótima	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,64%	223,52	3,56%	146,97	3,50%	120,46
Paraná	5,11%	74,50	3,38%	42,84	3,38%	43,66
Rio Gr. do Sul	7,28%	75,08	6,61%	70,78	4,98%	50,59
Santa Catarina	8,16%	84,07	4,91%	57,89	4,29%	44,85

Continua na próxima página.

Tabela 9.39 - Continuação da tabela.

	2017		2018		2019	
	2017		2018		2019	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	3,33%	94,87	1,89%	77,69	1,99%	65,28
	2020		2021		Média	
Híbrida	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Sul	6,73%	223,95	3,88%	152,24	3,56%	122,81

Na região Sul a abordagem que apresentou o melhor RMSE médio para o método de suavização exponencial foi a *top-down* e em segundo a abordagem híbrida. Já para o método de Box e Jenkins, a melhor abordagem foi a *bottom-up* e em segundo a combinação ótima.