

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA**

GUSTAVO NASCIMENTO WINTER ALVES

**PREVISÃO DE MERCADO: COMPETIÇÃO DE MÉTODOS APLICADA À PREVISÃO
DO CONSUMO DE ENERGIA ELÉTRICA NAS REGIÕES DO BRASIL**

Juiz de Fora

2023

GUSTAVO NASCIMENTO WINTER ALVES

**PREVISÃO DE MERCADO: COMPETIÇÃO DE MÉTODOS APLICADA À PREVISÃO
DO CONSUMO DE ENERGIA ELÉTRICA NAS REGIÕES DO BRASIL**

Monografia apresentada ao curso de Ciências
Econômicas da Universidade Federal de Juiz de
Fora como requisito parcial à obtenção do título
de bacharel em Ciências Econômicas.

Orientador: Dr. Alexandre Zanini

Juiz de Fora

2023

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Alves, Gustavo Nascimento Winter.

Previsão de mercado : Competição de métodos aplicada à previsão do consumo de energia elétrica nas regiões do Brasil / Gustavo Nascimento Winter Alves. -- 2023.

50 p.

Orientador: Alexandre Zanini

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2023.

1. Energia elétrica. 2. Previsão de consumo. 3. Séries temporais.
4. Competição de métodos. I. Zanini, Alexandre, orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 05/12/2023, a Banca Examinadora, composta pelos professores

- 1 – Alexandre Zanini - orientador; e
- 2 – Cláudio Roberto Fóffano Vasconcelos,

reuniu-se para avaliar a monografia do acadêmico **GUSTAVO NASCIMENTO WINTER ALVES**, intitulada: **PREVISÃO DE MERCADO: COMPETIÇÃO DE MÉTODOS APLICADA À PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NAS REGIÕES DO BRASIL**.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu **APROVAR** a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 05/12/2023, às 19:32, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Claudio Roberto Foffano Vasconcelos, Professor(a)**, em 05/12/2023, às 20:02, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1612130** e o código CRC **69E2C62C**.

RESUMO

Este trabalho busca entender o comportamento do mercado regional de energia elétrica e tem como objetivo principal estudar o consumo de energia elétrica por regiões no Brasil e fazer a previsão deste mercado no curto prazo. Para este fim, foi utilizada a análise estatística aplicada a séries de tempo. Foram aplicados dois métodos de previsão, o Método de Amortecimento Exponencial e o Método de Box & Jenkins, realizando-se uma competição entre eles para selecionar o modelo vencedor. O Método de Box & Jenkins foi definido como vencedor, pois teve melhor desempenho preditivo. Os modelos estimados projetaram um crescimento do consumo de energia elétrica no curto prazo em cada uma das regiões.

Palavras-chave: Energia elétrica. Previsão de Consumo. Séries Temporais. Amortecimento Exponencial. Box & Jenkins. Competição de Métodos.

ABSTRACT

This work seeks to understand the behavior of the regional electricity market and has as its main objective study electricity consumption by regions in Brazil and forecast this market in the short term. For this purpose, statistical analysis applied to time series was used. Two forecasting methods were applied, the Exponential Smoothing Method and the Box & Jenkins Method, with a competition between them to select the winning model. The Box & Jenkins Method was defined as the winner, as it had better predictive performance. The estimated models projected growth in electricity consumption in the short term in each region.

Keywords: Electricity. Consumption Forecast. Time Series. Exponential Smoothing. Box & Jenkins. Methods Competition.

LISTA DE FIGURAS

Figura 1- Procedimento de out-of-sample rolling evaluation	28
Figura 2- Consumo de Energia (GWh) por região	31
Figura 3- Gráficos de autocorrelação dos erros por região	36
Figura 4 - Consumo de energia (em GWh) – período de 1979 a 2024 Valores reais, ajustados e previsões com intervalo de confiança (IC) de 95%.....	37

LISTA DE TABELAS

Tabela 1- Resultado da Competição entre os Métodos de Previsão.....	33
Tabela 2- Equações de previsão para o consumo de energia elétrica nas regiões.....	35
Tabela 3- Teste de Ljung-Box por região	36
Tabela 4- Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Centro-Oeste	38
Tabela 5 - Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Nordeste.....	39
Tabela 6 - Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Norte.....	40
Tabela 7- Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Sudeste.....	41
Tabela 8 - Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Sul.....	42
Tabela 09: Consumo de energia elétrica anual (GWh) por região e variação percentual	42

LISTA DE QUADROS

Quadro 1- Resumo das características teóricas da FAC e da FACP dos modelos AR(p), MA(q) e ARMA (p,q)	25
--	----

LISTA DE SÍMBOLOS

\in	Pertence
α	Constante de amortecimento (parâmetro de nível)
β	Constante de amortecimento (parâmetro de tendência)
Σ	Somatório
∇	Operador de diferença
\prod	Produto de uma série de termos
\equiv	Identidade ou congruência
ρ	Parâmetro de sazonalidade
Θ	Operador sazonal de médias móveis
ε	Erro
Φ	Operador sazonal auto-regressivo
Υ	Autocovariância
τ	Horizonte de previsão
ϕ	Operador não sazonal auto-regressivo
θ	Operador não sazonal de médias móveis

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulada
ANEEL	Agência Nacional de Energia Elétrica
CCEE	Câmara de Comercialização de Energia Elétrica
CMSE	Comitê de Monitoramento do Setor Elétrico
CNPE	Conselho Nacional de Política Energética
EPE	Empresa de Pesquisa Energética
GWh	Gigawatt-hora = 10 ⁹ watts por hora (consumo)
MAE	Método de Amortecimento Exponencial
MBJ	Método de Box&Jenkins
MME	Ministério de Minas Energia
ONS	Operador Nacional do Sistema
SEB	Setor Elétrico Brasileiro
SIN	Sistema Interligado Nacional
UF	Unidade Federativa

SUMÁRIO

1. INTRODUÇÃO	11
2. REVISÃO DA LITERATURA	14
3. METODOLOGIA.....	17
3.1 MÉTODO DE AMORTECIMENTO EXPONENCIAL (MAE)	17
3.2 MÉTODO UNIVARIADO DE BOX & JENKINS (MBJ).....	24
3.2.1 MODELOS SARIMA	26
3.3 TESTES BASEADOS NA AUTOCORRELAÇÃO DOS RESÍDUOS.....	27
3.4 COMPETIÇÃO DE MÉTODOS.....	27
4. ANÁLISE DE DADOS	31
4.1 BASE DE DADOS	31
4.2 COMPETIÇÃO DE MÉTODOS.....	32
4.3 EQUAÇÕES DE PREVISÃO	34
4.4 PREVISÕES.....	37
5. CONCLUSÃO.....	44
REFERÊNCIAS	46

1. INTRODUÇÃO

O nível de consumo energia elétrica é considerado um dos principais indicadores do desenvolvimento econômico e do nível da qualidade de vida de uma nação, sinalizando o ritmo de atividade dos setores na economia e a capacidade da população para adquirir bens e serviços tecnologicamente mais avançados, impactando diretamente para o produto da economia (Atlas de energia elétrica, 2008).

Uma vez que a energia tem a capacidade de determinar o nível de evolução do desenvolvimento econômico, tal insumo pode ser considerado um recurso estratégico para a nação. Estudar e compreender os indicadores do setor elétrico constituem etapas fundamentais para a manutenção do setor, de modo a fornecer aos formuladores de políticas públicas e aos demais agentes econômicos informações confiáveis para avaliar o setor e estruturar planos de ação. Como suporte ao processo de tomada de decisão, utilizam-se os modelos de previsão para computar e, ao analisar as métricas do setor, busca-se minimizar os erros de estimação e fornecer dados fidedignos que possam ser empregados na manutenção do sistema e sua complexa estrutura.

O setor elétrico brasileiro (SEB) é composto por quatro segmentos: geração, transmissão, distribuição e comercialização de energia elétrica. A atual capacidade instalada do SEB é de aproximadamente 190.000 GigaWatts (ANEEL, 2023). A principal fonte de geração é a hidrelétrica, a qual em 2021, correspondia a 53,4% da produção nacional, de acordo com o Balanço Energético de 2022, desenvolvido pelo Ministério de Minas e Energia (MME), enquanto 21,3% são referentes às demais fontes renováveis. No que tange as matrizes que utilizam fontes não renováveis, tais como termoelétricas, usinas nucleares e movidas a combustíveis fósseis, essas representam somadas 21,9% da produção total. A porcentagem restante de 3,4% advém da importação da produção de países vizinhos, dentre eles o Paraguai com o qual o Brasil divide a operação e produção da usina hidroelétrica binacional de Itaipu (EPE, 2022).

Além da grande utilização da matriz hidroelétrica, o Brasil tem realizado grandes investimentos em outras fontes renováveis. No atual governo Lula há o projeto de entrega de oitenta e duas novas usinas, as quais serão instaladas em treze unidades da federação (UF), ampliando a capacidade de geração em diversas regiões do país, de acordo com o MME. Dentre essas usinas, no âmbito de energia renovável há quarenta e quatro de geração eólica, vinte e três solares e cinco hidroelétricas de pequeno porte (MME, 2023).

A transmissão da energia elétrica é realizada por meio de uma complexa rede de linhas de transmissão de energia, que compõem o Sistema Interligado Nacional (SIN). O SIN, é responsável pela operação de um amplo sistema hidrotérmico, o qual abarca usinas hidrelétricas, reservatórios e a transmissão da energia gerada. A distribuição é efetuada por empresas selecionadas por meio de concessões, concedidas pelo MME e por fim, a comercialização da energia para o consumidor final (MME, 2021).

A estrutura institucional responsável pela operação do SEB é composta por sete órgãos públicos. O MME, é responsável pela administração das políticas aplicadas no setor, ligado diretamente ao Conselho Nacional de Política Energética (CNPE), órgão este ligado diretamente ao poder executivo e responsável por assessorar a presidência da república na elaboração de políticas públicas. O Operador Nacional do Sistema (ONS) é a instituição responsável pela operação e manutenção do SIN, supervisionando diretamente toda a rede básica de transmissão de energia no país (MME, 2021).

Nos segmentos de distribuição e comercialização, há a atuação direta da Câmara de Comercialização de Energia Elétrica (CCEE), órgão responsável pela administração do ecossistema de comercialização de energia elétrica, integrando os quatro segmentos do SEB e organizando o mercado de energia e suas negociações, as quais são estruturados por meio por meio do Ambiente de Contratação Regulada (ACR) ou no Ambiente de Contratação Livre (ACL) (MME, 2021).

Submetida ao MME, está a Empresa de Pesquisa Energética (EPE), a qual, dada a importância estratégica do setor, tem como função a realização de pesquisas e estudos de planejamento voltados para o desenvolvimento do setor, de modo a garantir que esse seja organizado de maneira eficiente e sólida no longo prazo. Por fim, a Agência Nacional de Energia Elétrica (ANEEL) tem como função fiscalizar e regulamentar todos os segmentos do SEB aliada ao Comitê de Monitoramento do Setor Elétrico (CMSE), responsável por avaliar o abastecimento e a manutenção de sua continuidade (MME, 2021).

Dada a importância do setor elétrico na infraestrutura do país e a necessidade de se fazer planejamento energético, esta monografia busca entender o comportamento do mercado regional de energia elétrica, e tem como objetivo principal estudar a evolução histórica do consumo regional de energia elétrica, visando a estimação de modelos de previsão que possam fazer a previsão deste mercado.

Para atingir este objetivo, a monografia aplicou métodos de análise de séries temporais, mais especificamente dois métodos univariados ou autoprojativos e propôs uma competição entre eles visando selecionar o método vencedor para o cálculo da previsão.

Desta forma, este trabalho busca contribuir com a literatura existente, além disto visa gerar e fornecer informações confiáveis que possam ser utilizadas pelo poder público e demais agentes econômicos em seus processos de tomada de decisão e planejamento.

Após este capítulo introdutório, atenta-se que este presente trabalho foi organizado em mais cinco capítulos. No capítulo dois é apresentada uma revisão da literatura, no qual são apresentados trabalhos acadêmicos que contribuíram para o desenvolvimento da monografia e a literatura sobre o tema. No capítulo três é apresentada a metodologia utilizada. No capítulo quatro pode ser vista a análise de dados e principais resultados. Por fim, são apresentadas as conclusões.

2. REVISÃO DA LITERATURA

No ano de 1973 ocorreu uma crise internacional no fornecimento de petróleo, o que levou a uma severa restrição no abastecimento global, frente a esse cenário o governo brasileiro buscou manter os níveis de produção do petróleo energia elétrica e aço, insumos fundamentais para as operações de expansão e manutenção da infraestrutura e do funcionamento da economia (Lorenzo, 2002).

Entretanto, com o choque do petróleo a economia brasileira se viu fragilizada, com o Estado incapaz de sustentar a expansão econômica e a manutenção do nível de atividade vigente. Na década de 1980, com a escassez de recursos os investimentos no setor elétrico foram drasticamente reduzidos, o que culminou no congelamento das tarifas e extinção do piso da remuneração para as concessionárias de energia, de modo a provocar uma intensa crise no fornecimento em diversas regiões do país, racionamentos de energia entraram em vigor e diversos apagões foram registrados. Além disso, devido ao corte sofrido pelas concessionárias a ocorrência de inadimplência apresentou um salto vertiginoso, o que fragilizou ainda mais o setor em meio à crise (Schor, 2018).

Na década de 1990 o Brasil apresentava um setor elétrico desorganizado, com baixa arrecadação e sem possibilidade de suporte de investimentos estatais, mediante tal conjuntura se fez necessária a reformulação da estrutura do setor, por meio da ampliação da iniciativa privada e redução da participação do estado (Lorenzo, 2002).

De acordo com Schor (2018), durante o mandato de Fernando Henrique Cardoso, estabeleceu-se a criação da autarquia Agência Nacional de Energia Elétrica (ANEEL), além do Governo iniciar o processo de reestruturação do SEB, em resposta ao período crítico enfrentado pelo sistema após o choque do petróleo. Os principais objetivos do programa RE-SEB eram o de garantir a oferta de energia mediante um mercado competitivo, de fácil acesso, com produtores diversos e que, com sua eficiência e regulação justa, fosse um ambiente atraente para novos investidores e seguro para os consumidores.

No ano de 1998, o setor passou por profundas reestruturações, tais como as promovidas pelo Decreto Nº 2.655, o qual tinha como função a manutenção do bom funcionamento do mercado de energia e seu desenvolvimento, tarefa essa gerida pelo Mercado Atacadista de Energia Elétrica, além do estabelecimento das diretrizes operacionais do NOS dentro do sistema (ONS, 2021).

Outro aspecto importante do RE-SEB foi a desverticalização do setor, promovida pela redução do papel do Estado como único fornecedor e a instauração de um mercado competitivo

e atraente para a iniciativa privada, o que preencheu lacunas geográficas no que tange o fornecimento, elevou a capilaridade, otimizou os componentes do SEB e melhorou a qualidade do serviço em todo o território nacional (Silva 2011).

Na estrutura em vigor atualmente no Brasil, o mercado de energia elétrica mantém o aspecto de livre mercado advindo do RE-SEB, a capacidade geradora dos agentes privados dita o nível de oferta do mercado e seu horizonte de produção. Dentro desse mercado existem duas modalidades de negociação, a primeira é o Ambiente de Contratação Regulada (ACR), no qual a comercialização entre os agentes ocorre sob processo de licitação, com seu preço já determinado. A segunda modalidade é a de Contratação Livre (ACL), nesse modelo o comércio se dá por contratos bilaterais com regras específicas a serem decididas pelas partes envolvidas (Vieira, 2011).

Entendidas algumas características do SEB, este trabalho monográfico fez uma revisão da literatura dos modelos de previsão, com o objetivo de entender e embasar o processo de construção do arcabouço teórico desse estudo, no que se refere à compreensão do emprego de métodos preditivos para a análise regional do SEB.

Oliveira (2022) emprega três métodos auto projetivos para a estimação do consumo mensal total de energia elétrica no Brasil. No estudo, o autor realiza a competição entre o Método de Amortecimento Exponencial, Método de Box & Jenkins e Rede Neural Artificial a fim de avaliar suas capacidades preditivas e determinar o melhor modelo. Para a estimação da equação de previsão, adotou-se o processo de decomposição das séries temporais em nível, tendência, sazonalidade e erro, de acordo com o trabalho de Harvey e Peters (1990, apud Oliveira, 2022). Após a decomposição, o autor analisa a estrutura de correlação dos dados das séries, estima os parâmetros e efetua a comparação dos valores reais da série com os valores modificados pelo modelo, por meio da comparação se obtém o nível de erro do método e é determinado o seu desempenho frente aos concorrentes.

Silva (2022) mensurou os impactos da pandemia no consumo de energia elétrica nas regiões do Brasil por meio da utilização do Método de Amortecimento Exponencial com abordagens em múltiplos níveis. A fim de captar os efeitos causados pela pandemia, o autor realizou uma análise de eventos em conjunto com duas abordagens, a primeira é a *top-down*, que consiste na utilização do modelo estimado para o consumo total, a qual não utiliza os modelos por região, de modo a desagregar as previsões obtidas pelos modelos. Já a abordagem *bottom-up* realiza a agregação das previsões dos modelos regionais, o que permite a construção da previsão para o consumo total.

O estudo acerca de metodologias de previsão aplicadas à modelagem do consumo de energia elétrica no Brasil aponta ainda para os trabalhos de Vitor (2021), Sampaio (2021), Ruza (2021), Santos Junior (2021), Souza (2019), Miranda (2019), Chain (2019), Faria (2019), Neto (2019), Tavares (2018), Pereira (2018), Ferreira (2018), Mendes Junior (2018), Mattos (2018), Assis (2017) e Cândido (2017).

Feitas estas considerações, no próximo capítulo será apresentada a metodologia aplicada neste trabalho monográfico para calcular a previsão do consumo de energia elétrica por região no Brasil.

3. METODOLOGIA

Atenta-se que toda a estrutura metodológica utilizada nesta seção é baseada em Zanini (2023).

3.1 MÉTODO DE AMORTECIMENTO EXPONENCIAL (MAE)

No Método de Amortecimento Exponencial se dá pesos diferenciados para a “idade” da informação, ou seja, o quão recente é a informação na série. Para séries com maior variância, pode-se dar um peso maior para as informações mais recentes, ao passo que séries com menor variância permitem ponderar de forma igual tanto para dados presentes quanto dados passados. Além disso, uma extensão desse modelo pode ser feita ao incluir parâmetros de tendência (alterações do nível da série) e sazonalidade (movimento cíclico da série no decorrer do tempo) para modelar o comportamento de determinada série temporal, estruturando um “sistema” o qual possa reestimar os parâmetros do modelo a cada período de tempo incorporando a informação mais recente.

Para fim de exemplificação da aplicação do Método de Amortecimento Exponencial, considera-se que o conjunto de observações Z_1, Z_2, \dots, Z_T seja uma série temporal de tamanho “T”.

A série apresentada representará, por exemplo, um produto de determinada empresa cuja demanda mensal não apresenta uma variação significativa no seu nível ao longo do tempo. Logo, não ocorrem mudanças no nível de venda com o tempo ou apresenta variações pouco significativas. Para este produto, a equação de previsão pode ser representada por:

$$Z_t = a(T) + \varepsilon_t \quad (3.1)$$

Onde:

Z_t = venda no período t ($t = 1, 2, \dots, T$);

$a(T)$ = parâmetro representativo do nível médio das vendas no instante T ;

ε_t = erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

Uma vez que o produto apresente um nível de venda quase constante, a estimativa ($\hat{a}(T)$) para o parâmetro “a” na equação (3.1) fornece diretamente uma previsão para o produto analisado. Tal cenário permite que o parâmetro possa ser estimado de diversas formas, como

por exemplo a estimação “autoprojetiva”, que por meio do modelo ingênuo (ou *naive*) utiliza como predictor o último dado conforme indicado pela equação (3.2) a seguir:

$$\hat{Z}_T(\tau) = Z_T \quad (3.2)$$

Onde:

$\hat{Z}_T(\tau)$: previsão para Z_T , τ passos-à-frente (ou previsão de $Z_{T+\tau}$ feita no instante T);

Z_T : último dado disponível

τ : horizonte de previsão

Além disso, há outras formas de estimação do parâmetro “a” na equação (3.1). Poderiam ser utilizadas uma **média** ou uma **média móvel** dos dados históricos (equações (3.3) e (3.4) respectivamente).

$$\hat{a}(T) = \bar{Z}_T = \frac{1}{T} \sum_{i=1}^T Z_i \quad (3.3)$$

$$\hat{a}(T) = MM(N) = M_T = \frac{Z_T + Z_{T-1} + Z_{T-N+1}}{N} \quad (3.4)^1$$

Onde:

MM(N): média móvel de tamanho N.

Nas estimações por média e média móvel existe uma desvantagem que diz respeito ao fato de que todos os dados entram com o mesmo “peso”, ou seja, $1/N$. Falha esta que é corrigida pelas atualizações dos parâmetros realizadas pelo MAE ao considerar a tendência e sazonalidade ao modelar o comportamento da série de tempo. Para a elaboração do sistema, citado no início deste capítulo, consideram-se duas informações:

- 1 - A estimativa de “a” feita no final do período anterior $\hat{a}(T-1)$;
- 2 - O último dado disponível $Z(T)$;

¹ Uma vez que $M_T = M_{T-1} + \frac{Z_T - Z_{T-N}}{N}$.

Utilizando essas informações, será calculada uma estimativa atualizada do nível de venda: $\hat{a}(T)$. Como opção de solução do sistema é feita uma modificação na estimativa velha ($\hat{a}(T-1)$) do nível por uma fração do erro de previsão resultante do uso desta estimativa para o dado mais recente. Uma vez que o erro de previsão no último período pode ser definido como $\varepsilon(T) = Z(T) - \hat{a}(T-1)$, a formulação matemática para esta proposta está representada na equação abaixo:

$$\hat{a}(T) = \hat{a}(T-1) + \alpha*[Z(T) - \hat{a}(T-1)] \quad (3.5)$$

$$\hat{a}(T) = \alpha*Z(T) + (1 - \alpha)*\hat{a}(T-1) \quad (3.6)$$

Como simplificação da notação, define-se que $\hat{a}(T) \equiv S_T$. Desta forma, ao reescrever a equação (3.6) acima tem-se que:

$$S_T = \alpha*Z_T + (1 - \alpha)*S_{T-1} \quad (3.7)^2$$

Onde:

S_T = valor amortecido da série;

α = constante de amortecimento ou hiperparâmetro (número entre 0 e 1).

Por meio da formulação (3.7) é possível afirmar que no MAE ocorrerá a atualização automática do parâmetro “a”, que representa o nível de consumo na equação (3.1), será feita uma combinação convexa³, onde é dado um peso α para o “presente” (último dado) e um peso $(1 - \alpha)$ para o “passado” (estimativa anterior para o nível e que pode ser obtida de várias formas como, por exemplo, uma média, uma média móvel, dentre outras)⁴. Os procedimentos de

² A equação (3.7) é também conhecida como Modelo de Brown.

³ A soma é igual a 1.

⁴ Para mais detalhes, ver MONTGOMERY & JOHSON (1990). Como um exemplo, imagine que se esteja trabalhando com dados mensais no período de janeiro de 2018 a dezembro de 2022. Neste caso, a equação (3.6) informa que a atualização do parâmetro de nível (portanto a previsão para o dado de janeiro de 2023, dado que o modelo para a venda é constante) será feita dando-se um peso α para o dado de dezembro de 2022 e um peso $(1 - \alpha)$ para a última estimativa feita para o dado de dezembro de 2022 (feita obviamente em novembro de 2022).

atualização dos parâmetros devem manter a estrutura onde são dados pesos diferenciados para “presente” e “passado”, ou seja, fazendo-se:

$$\alpha * \textit{Presente} + (1-\alpha) * \textit{Passado}$$

Entretanto, o modelo não é adequado se houver um componente de tendência na série, sendo necessário utilizar o modelo a seguir⁵:

$$Z_t = (a_1(T) + a_2(T) * t) + \varepsilon_t \quad (3.8)$$

Onde:

$a_1(T)$: parâmetro de nível no instante T;

$a_2(T)$: parâmetro de tendência no instante T;

t: variável tempo (t = 1, 2, ..., T sendo T é a quantidade de dados existentes);

ε_t é o erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

O **Modelo de Holt-2Parâmetros** consiste na aplicação de um sistema de atualização paramétrica semelhante ao apresentado na equação (3.7), sobre os parâmetros da equação (3.8). A atualização dos parâmetros pode ser feita de acordo com as equações (3.9) e (3.10) abaixo:

$$\hat{a}_1(T) = \alpha * Z_T + (1 - \alpha) * \left[\hat{a}_1(T-1) + \hat{a}_2(T-1) \right] \quad (3.9)$$

$$\hat{a}_2(T) = \beta * \left[\hat{a}_1(T) - \hat{a}_1(T-1) \right] + (1 - \beta) * \left[\hat{a}_2(T-1) \right] \quad (3.10)$$

Observa-se que as equações (3.9) e (3.10) apresentam a mesma ideia de se ponderar “presente” e “passado” para se fazer a atualização dos parâmetros. Entretanto, vê-se que são usadas duas constantes de amortecimento (α e β), uma para o parâmetro de nível (a_1) e outra para o parâmetro de tendência (a_2).

Na equação (3.9), a atualização do parâmetro de nível é realizada dando um peso α para o dado real mais recente e um peso $(1 - \alpha)$ para a última estimativa feita para o nível que é composta por: $\hat{a}_1(T-1)$, estimativa feita para o nível no instante anterior (T-1), mais $\hat{a}_2(T-1)$, que

⁵ Verifique que, diferentemente da equação (3.1), existem agora dois parâmetros e por isto é feita a diferença entre a_1 e a_2 .

é a estimativa feita para a tendência também no instante anterior (T-1). Logo, pode-se evidenciar que na atualização do parâmetro de nível, dá-se um peso para o último dado (fornecendo uma representação real e atualizada para o nível) e um outro peso para um valor estimado para este nível quando se estava no momento anterior (“passado”).

Já a equação (3.10), ao atualizar o parâmetro de tendência, observa-se que é dado um peso β para a diferença entre a nova estimativa do nível, calculada na equação 3.9, e a última estimativa do nível, realizada no instante anterior T-1, caracterizando um componente de tendência ou taxa de crescimento. Ao determinar um peso β para esta estimativa “presente” do parâmetro de tendência, é atribuído um peso $(1 - \beta)$ para a última estimativa da tendência feita no instante anterior (T-1).

Para além das estimativas dos parâmetros de nível e tendência, para se desenvolver um modelo autoprojeto ou univariado, é necessário que todos os “fatores” que integram a série de tempo sejam estimados. Para alcançar tal objetivo deve-se considerar também a existência de um comportamento cíclico na série temporal, denominado sazonalidade. Tal parâmetro impacta o volume de vendas positivamente ou negativamente dependendo do período do que em que se encontra, constituindo ciclos ao decorrer do tempo. Esse modelo é denominado **Modelo de Holt-Winters** e pode⁶ ser expresso pela equação (3.11):

$$Z_t = (a_1(T) + a_2(T) * t) * \rho_t + \varepsilon_t \quad (3.11)$$

$a_1(T)$: parâmetro de nível no instante T;

$a_2(T)$: parâmetro de tendência no instante T;

t: variável tempo ($t = 1, 2, \dots, T$ sendo T é a quantidade de dados existentes);

ρ_t : fator sazonal referente ao período t;

ε_t é o erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

⁶ É dito “pode”, pois a equação apresenta uma sazonalidade multiplicativa, entretanto, pode-se encontrar também uma sazonalidade aditiva.

Analisando os componentes da equação nota-se a adição de um novo parâmetro para “captar” o efeito da sazonalidade⁷ sobre as vendas. Vale destacar que ocorrerá um procedimento de atualização paramétrica similar ao apresentado na equação (3.7), de modo a promover uma atualização sequencial dos parâmetros do Modelo de Holt-Winters, como representado nas equações (3.12) a (3.14) a seguir:

$$\hat{a}_1(T) = \alpha * \frac{Z_T}{\hat{\rho}_t(T-1)} + (1-\alpha) * \left[\hat{a}_1(T-1) + \hat{a}_2(T-1) \right] \quad (3.12)^8$$

$$\hat{a}_2(T) = \beta * \left[\hat{a}_1(T) - \hat{a}_1(T-1) \right] + (1-\beta) * \left[\hat{a}_2(T-1) \right] \quad (3.13)^9$$

$$\hat{\rho}_t(T) = \gamma * \frac{Z_T}{\hat{a}_1(T)} + (1-\gamma) * \left[\hat{\rho}_t(T-1) \right] \quad (3.14)$$

Ao analisar a equação (3.12) observa-se que o nível estimado está em função da última observação, do fator sazonal estimado no instante anterior (mesmo mês do ano anterior) e estimativas anteriores de nível e tendência. Destaca-se que o termo: $\frac{Z_T}{\hat{\rho}_t(T-1)}$ representa a

observação no instante T dessazonalizada. A equação (3.13) indica que a tendência estimada é função dos níveis estimados em T e T-1 e da taxa de crescimento estimada anteriormente¹⁰, considerando que a constante de amortecimento (β) é diferente da constante (α) usada para

⁷ Existem uma restrição de normalização que faz com que $\sum_{i=1}^L \rho_i = L$, onde L é o comprimento do período sazonal. Isto é, caso se esteja trabalhando com dados mensais e um parâmetro de sazonalidade multiplicativo, a soma dos fatores sazonais precisa ser igual a 12 (obviamente pois existem 12 meses em um ano).

⁸ Onde $\hat{\rho}_t$ é o fator sazonal correspondente ao período (mês, trimestre, etc) t.

⁹ Trata-se da mesma equação (3.10).

¹⁰ Como visto anteriormente, a constante de amortecimento (β) é diferente daquela (α) usada para atualização do nível.

atualização do nível da série. Além disso, observa-se na equação (3.14) a atualização de parâmetros por meio da atribuição de diferentes pesos às informações, dependendo do quão recentes são, de modo a avaliar o “presente” e o “passado” da série de maneiras distintas. Por fim, a equação (3.14) destaca que o fator sazonal correspondente ao período T é função do fator sazonal correspondente ao mesmo período no ano anterior e também da última observação.

Desse modo, pode-se concluir que ao analisar um fator sazonal de uma única ocorrência anual, só é atualizado ao ser adicionado o dado referente a essa ocorrência no período seguinte. Como por exemplo, um mês o qual teria seu fator sazonal atualizado quando fosse obtido o novo dado desse mês no ano seguinte (ocorrendo uma vez ao ano).

Destaca-se que agora há três constantes de amortecimento (α , β e γ), apresentando um único valor, obtido por meio do histórico de dados analisados. Tais constantes serão consideradas durante as atualizações dos parâmetros de nível, tendência e sazonalidade. Portanto, a constante de amortecimento pode ser definida como uma quantidade fixa que é utilizada para fazer a atualização sequencial dos parâmetros. Este conceito caracteriza o modelo obtido através do método de amortecimento exponencial como um modelo com “validade local”, ou seja, a cada instante de tempo, a cada dado real que chega, é feita uma atualização dos parâmetros do modelo com base nas equações descritas anteriormente, sendo que os fatores responsáveis por esta atualização são exatamente as constantes de amortecimento ou hiperparâmetros.

Em determinadas situações, faz-se fundamental intervir nos valores projetados por um modelo do tipo Holt (equação 3.8). No modelo de Holt, vê-se que são estimados dois parâmetros, um para o nível e outro para a tendência. Dependendo da “magnitude” do parâmetro de tendência, pode-se gerar previsões “explosivas” (muito altas) no horizonte de previsão. Uma maneira de se corrigir este problema, é realizar o que se denomina de *damped trend*. Neste procedimento, inclui-se mais um hiperparâmetro no modelo conforme a equação 3.15 a seguir. Esta equação já representa a equação de previsão. Vê-se que a função deste hiperparâmetro é reduzir a tendência no horizonte de previsão.

$$Z_t = \hat{a}_1(T) + \sum_{j=1}^{\tau} \varphi^{j-1} * \hat{a}_2(T) * \tau + \varepsilon_t \quad (3.15)$$

É importante entender que foram apresentados os modelos de amortecimento exponencial e as conseguintes equações de atualização paramétrica. Desta forma, é importante que se tenha em mente a forma da equação que gerará as previsões. Para cada um dos casos (vendas constantes, vendas com tendência e vendas com tendência e sazonalidade), a equação de previsão é apresentada a seguir nas equações (3.16) a (3.18):

$$\hat{Z}_t(\tau) = \hat{a}_1(T) + \varepsilon_t \quad (3.16)$$

$$\hat{Z}_t(\tau) = \hat{a}_1(T) + \hat{a}_2(T) * \tau + \varepsilon_t \quad (3.17)^{11}$$

$$\hat{Z}_t(\tau) = \left(\hat{a}_1(T) + \hat{a}_2(T) * \tau \right) * \hat{\rho}_{p(T+\tau)}^{(T)} + \varepsilon_t \quad (3.18)^{12}$$

3.2 MÉTODO UNIVARIADO DE BOX & JENKINS (MBJ)

O Método de Box & Jenkins (MBJ)¹³, que tem como base a Teoria Geral de Sistemas Lineares, a qual descreve que a passagem de um ruído branco por um filtro linear de memória infinita, gera um processo estacionário de segunda ordem, configurando um processo estocástico com sua média e variância constantes.

Primeiramente, é preciso transformar a série de modo que fique estacionária, para tal busca-se identificar a ordem de homogeneidade “d”, por meio da análise do gráfico da função de autocorrelação (FAC)¹⁴ ou da própria série. Uma vez obtida a ordem de homogeneidade, se saberá quantas vezes a série original de terá de ser diferenciada para que fique estacionária.

Em seguida, ocorre a identificação do modelo, ou seja, da sua ordem (identificação de p e q), observando como se comportam a função de autocorrelação (FAC) e autocorrelação parcial (FACP) ao analisar seus correlogramas.

No quadro abaixo estão resumidas as características dessas funções para os modelos AR(p), MA(q) e ARMA (p,q).

¹¹ Notação para quando há deslocamento de origem. Caso contrário faz-se (T+τ).

¹² Idem.

¹³ Box & Jenkins (1994).

¹⁴ A Função de Autocorrelação para uma série não estacionária apresenta um lento decréscimo.

Quadro 1 - Resumo das características teóricas da FAC e da FACP dos modelos AR(p), MA(q) e ARMA (p,q)

Modelo	Função de Autocorrelação (ρ_k)	Função de Autocorrelação Parcial (ϕ_{kk})
AR(p)	Infinita (Exponencial e/ou senóides amortecidas)	Finita (Corte após o <i>lag</i> “p”)
MA (q)	Finita (Corte após o <i>lag</i> “q”)	Infinita (Exponencial e/ou senóides amortecidas)
ARMA (p,q)	Infinita (Exponencial e/ou senóides amortecidas após o <i>lag</i> “q-p”)	Infinita (Exponencial e/ou senóides amortecidas após o <i>lag</i> “p-q”)

Fonte: Zanini (2023)

No modelo AR(p), analisa-se se há decrescimento da FAC e se a FACP apresenta um corte¹⁵, para identificar a ordem p. Caso essas condições de cumpram, o *lag* onde este corte ocorre nos fornece a ordem p ($p = \textit{lag}$ do corte).

Já no modelo MA (q) a FAC e a FACP têm comportamento inverso ao de um modelo puramente autoregressivo, de modo que a FACP passa a apresentar decrescimento e a FAC nos indica o corte. Logo, *lag* onde este corte ocorre fornece a ordem q do modelo MA.

Com a identificação da ordem do modelo efetuada, a próxima etapa é obter as estimativas dos parâmetros do modelo, por meio da técnica da máxima verossimilhança¹⁶.

Por fim, uma vez identificado o modelo e estimados os parâmetros, executam-se os testes de aderência para verificar a adequabilidade final do modelo, abarcando testes para os resíduos e os testes de sobrefixação.

Um dos indicadores de eficiência explicativa do modelo ocorre após estruturação do modelo e é obtido ao realizar os testes para os resíduos. Busca-se explicar de maneira fidedigna o comportamento da série de tempo de modo que o erro não apresente correlação, classificando o resíduo gerado pelo modelo como um ruído branco.

O teste de sobrefixação, por sua vez, consiste simplesmente em se gerar modelos de ordem superior ao identificado, de forma que se possa reforçar a pertinência deste.

¹⁵ Geralmente nos *softwares* específicos para previsão, tanto o gráfico da FAC quando da FACP apresentam intervalos de significância dos *lags*. Os *lags* cujos valores da autocorrelação ultrapassam estes intervalos são ditos significantes (Goodrich & Stellwagem, 1999). Caso se observe, por exemplo, a autocorrelação de *lag* 1 significativo e, a partir do *lag* 2 (inclusive), as autocorrelações estão todas dentro do intervalo, isto indica um “corte” no *lag* 1.

¹⁶ Dudewicz & Mishra, 1988.

3.2.1 MODELOS SARIMA

Para a construção de modelos voltados para séries temporais com componentes sazonais, Box & Jenkins estruturaram os modelos SARIMA, os quais seguiam os mesmos passos para a obtenção de um modelo ARIMA não sazonal, porém desta vez, apesar da simples observação da FAC e FACP, a observação dos *lags* de corte passou para os *lags* sazonais. O modelo apresenta a estrutura SARIMA(p,d,q)x(P,D,Q) e sua modelagem segue a equação (3.19) abaixo:

$$\phi(B)\Phi(B^S)\nabla_S^D\nabla^d Z_t = \theta(B)\Theta(B^S)a_t \quad (3.19)$$

Onde:

$\phi(B)$: operador não sazonal auto-regressivo

ϕ_i : parâmetros auto-regressivo não-sazonais

$\nabla^d = (1-B)^d$: operador diferença não sazonal de ordem d

$\Phi(B^S)$: operador sazonal auto-regressivo

Φ_i : parâmetros auto-regressivo sazonais

$\nabla_s^D = (1-B^S)^D$: operador diferença sazonal de ordem D

$\theta(B)$: operador não sazonal de médias móveis

θ_i : parâmetros de médias móveis não sazonais

$\Theta(B^S)$: operador sazonal de médias móveis

Θ_i : parâmetros de médias móveis sazonais

3.3 TESTES BASEADOS NA AUTOCORRELAÇÃO DOS RESÍDUOS

A seguir é apresentado o teste de Ljung-Box ou Portmanteu que é baseado na Função de Autocorrelação dos Resíduos (FAC) de um modelo.

Testa-se a hipótese de que as "k" primeiras autocorrelações são nulas, isto é:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$$

A estatística de teste é apresentada na equação (3.20):

$$Q = \frac{T * (T + 2) \sum_{i=1}^k r_i^2}{T - 1} \quad (3.20)$$

A estatística Q, dado que H_0 é verdadeira, segue uma distribuição Qui-quadrado (χ^2) com "k-m" graus de liberdade, onde "m" é o número de parâmetros livres do modelo. Desta forma, na regra de decisão, rejeita-se a hipótese nula (autocorrelações nulas) se Q é "grande" quando comparado a um percentil apropriado da densidade Qui-quadrado.

É importante verificar que, caso se observe algumas correlações estimadas altas (r^2 na equação 3.20), pode-se enviesar para mais o valor de Q o que, por consequência pode levar à rejeição da hipótese nula de ruídos descorrelatados. Desta forma, é importante realizar o teste de Ljung-Box analisando-se, ao mesmo tempo, o correlograma dos resíduos.

3.4 COMPETIÇÃO DE MÉTODOS

A competição dos métodos utilizada neste trabalho monográfico se baseará numa análise recursiva fora da amostra com deslocamento da origem. Essa técnica, primeiramente retira um conjunto de dados da amostra para avaliar o poder de generalização dos modelos, ou seja, como os modelos se comportam ao prever a realidade mais recente. Para isto, são feitas análises *in-sample* e *out-of-sample*, de modo a possibilitar a observação dos valores reais das variáveis e também seus valores que sofreram alterações.

Em seguida, realiza-se uma análise recursiva fora da amostra (*out-of-sample rolling evaluation*), movendo-se a origem da previsão para cada dado retirado da amostra inicialmente, calculando-se as previsões para cada horizonte de previsão, de modo a gerar um número maior de previsões fora da amostra. Neste trabalho utilizou-se os últimos 12 meses dos dados, de modo a gerar 78 previsões totais no período *out-of-sample*. Para exemplificar, o cálculo que

resultará no número de previsões obtidas inicia-se com 12 previsões para um mês à frente, seguidas por 11 previsões para dois meses à frente, 10 previsões para três meses à frente e assim sucessivamente até 1 previsão para 12 meses à frente. Tal raciocínio está ilustrado na figura 1, a seguir.

Figura 1- Procedimento de out-of-sample rolling evaluation

		HORIZONTE											
		jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
ORIGEM	dez	A	A	A	A	A	A	A	A	A	A	A	A
	Jan	F	F	F	F	F	F	F	F	F	F	F	F
	Fev	A	A	F	F	F	F	F	F	F	F	F	F
	mar	A	A	A	F	F	F	F	F	F	F	F	F
	abr	A	A	A	A	F	F	F	F	F	F	F	F
	mai	A	A	A	A	A	F	F	F	F	F	F	F
	Jun	A	A	A	A	A	A	F	F	F	F	F	F
	Jul	A	A	A	A	A	A	A	F	F	F	F	F
	ago	A	A	A	A	A	A	A	A	F	F	F	F
	set	A	A	A	A	A	A	A	A	A	F	F	F
	out	A	A	A	A	A	A	A	A	A	A	F	F
	nov	A	A	A	A	A	A	A	A	A	A	A	F

Fonte: Zanini (2023)

Nota: F = Forecast; A = Actual

Uma vez que as previsões fora da amostra são geradas, são analisadas seis métricas, sendo duas dentro da amostra e quatro fora da amostra. O critério a ser utilizado para avaliar qual modelo detém a melhor capacidade preditiva consiste em verificar a capacidade de generalização dos modelos, ou seja, qual modelo prevê melhor a realizada mais recente (período utilizado como fora da amostra) e qual modelo possui maior poder de explicação e menor medida de erro tanto dentro quanto fora da amostra. Selecionado o modelo vencedor, os dados retirados anteriormente são novamente reincorporados à amostra e os parâmetros dos modelos são atualizados para que sejam calculadas as previsões.

A primeira métrica é o MAPE (*Mean Absolute Percentual Erro*), que representa o erro médio absoluto percentual e é calculado através da diferença entre valores estimados e reais e equivale às previsões um passo-à-frente (por exemplo, para o mês seguinte). Cálculo expresso na equação (3.21) a seguir:

$$MAPE = \frac{\sum_{t=1}^N \frac{|Y(t) - \hat{Y}(t)|}{Y(t)}}{N} \times 100 \quad (3.21)$$

Onde:

$Y(t)$ = valor da série temporal no período (t);

$\hat{Y}(t)$ = valor ajustado da série temporal para o período (t);

N = total de dados utilizados (total de observações).

A segunda métrica escolhida foi o GMRAE (*Geometric Mean Relative Absolute Error*), a qual compara o erro do modelo estimado com o erro do modelo ingênuo (que usa como previsão o último dado disponível). O GMRAE é a média geométrica da razão (quociente) entre o erro absoluto (portanto, em módulo) do modelo estimado e o erro absoluto do método ingênuo. Logo, é desejável que o GMRAE seja igual ou menor do que 1. Cálculo expresso na equação (3.22) a seguir:

$$GMRAE = \sqrt[N]{\frac{\sum_{t=1}^N |Y(t) - \hat{Y}(t)|}{\sum_{t=1}^N |Y(t) - Y(t-1)|}} \quad (3.22)$$

Onde:

$Y(t)$ = valor da série temporal no período (t);

$\hat{Y}(t)$ = é a previsão da série temporal para o período (t);

$Y(t-1)$ = valor da série temporal no período (t-1);

N = número de observações.

Por fim, há o coeficiente de explicação ajustado (R^2 ajustado), que indica o quanto da variação total dos dados (série dependente) é explicada pelo modelo. Entretanto, faz-se uma correção tendo em vista a quantidade de parâmetros no modelo. Cabe ressaltar que o coeficiente de explicação (ou determinação) varia entre 0 e 100%. Veja a equação (3.23) a seguir:

$$R^2_{ajust} = \left(1 - \frac{\sum_{t=1}^N \frac{(Y(t) - \hat{Y}(t))^2}{N-k}}{\sum_{t=1}^N \frac{(Y(t) - \bar{Y})^2}{N-1}} \right) \times 100 \quad (3.23)$$

Onde:

$Y(t)$ = valor da série temporal no período (t);

$\hat{Y}(t)$ = previsão da série temporal para o período (t);

\bar{Y} = média das observações (média da série temporal);

N = total de dados utilizados (total de observações);

k = número de parâmetros do modelo.

Ao final, como dito anteriormente, são analisados seis critérios (dois *in-sample* e quatro *out-of-sample*) para decidir qual o método vencedor e que será utilizado para calcular as previsões de consumo de energia elétrica nas regiões do Brasil. Definido o método vencedor, os dados retirados inicialmente são novamente incorporados à amostra, os parâmetros reestimados e as previsões calculadas.

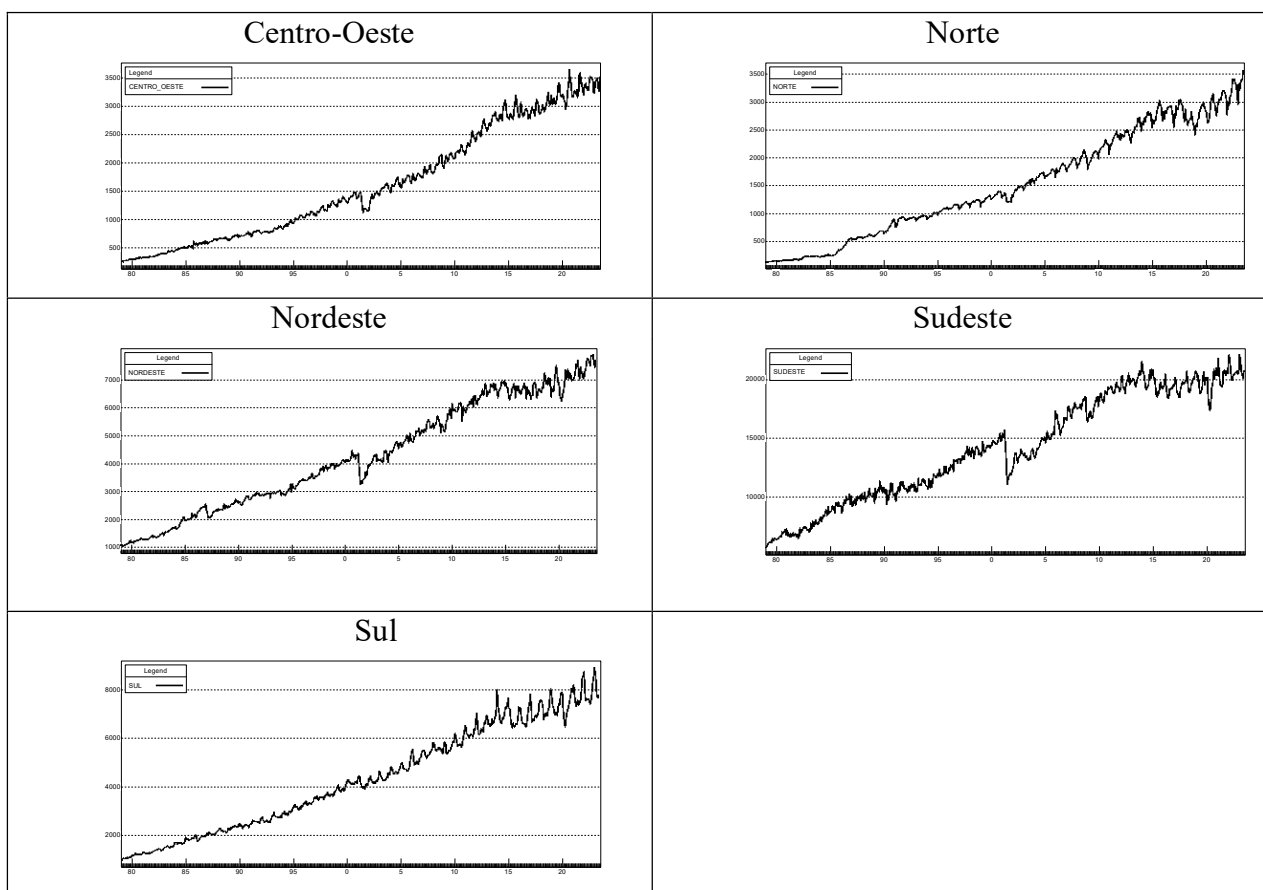
Apresentada a metodologia utilizada neste trabalho monográfico, no próximo capítulo podem ser vistas informações sobre a base de dados e a análise dos resultados encontrados.

4. ANÁLISE DE DADOS

4.1 BASE DE DADOS

Para a estimação dos modelos de previsão utilizou-se os dados de consumo de energia elétrica mensal, em GWh, de cada região, registrados pela Eletrobrás (IPEADATA, 2023). A série de tempo utilizada compreende o período de janeiro de 1979 a agosto de 2023, as previsões, estimativas e informações sobre as séries foram geradas por meio do *software Forecast Pro for Windows* (FPW). A figura 02 a seguir apresenta a série histórica do consumo em GWh das cinco regiões analisadas.

Figura 2- Consumo de Energia (GWh) por região



Fonte: Elaboração própria.

A opção por se trabalhar com todo o conjunto de dados disponíveis, ou seja, a partir de 1979, foi devido ao fato deste trabalho monográfico objetivar entender a dinâmica da evolução do consumo de energia elétrica em cada uma das regiões. É possível verificar na figura 02 uma evolução crescente deste consumo, podendo-se identificar claramente

tendências de crescimento diferentes nos diversos períodos da economia brasileira. É possível ainda identificar visualmente algumas interrupções neste crescimento como, por exemplo, o choque de oferta ocorrido no início dos anos 2000 e, mais recentemente, a pandemia da Covid-19. Atenta-se que alguns trabalhos referenciados no capítulo dois abordaram a modelagem destes “eventos”.

Na seção seguinte deste capítulo será apresentada a competição de métodos, a análise dos resultados obtidos e a definição dos métodos vencedores.

4.2 COMPETIÇÃO DE MÉTODOS

O processo de escolha do melhor método de previsão para cada uma das regiões consistiu na realização de uma análise recursiva fora da amostra com deslocamento da origem. Como pode ser visto no capítulo 3, num primeiro momento, foram retirados os últimos 12 meses (setembro de 2022 a agosto de 2023) para compor o período fora da amostra. Foram geradas então 78 previsões fora da amostra para diferentes horizontes (H) de previsão (H = 1 até H = 12). Os resultados obtidos foram sintetizados e estruturados na Tabela 01 a seguir para comparação das métricas dos dois modelos para cada região. Para dentro da amostra são apresentados o poder de explicação (R^2 ajustado) e o MAPE. Já para dentro da amostra são apresentados o MAPE e o GMRAE das 12 previsões 1 passo à frente, e ambas as medidas no acumulado das 78 previsões.

Observando a Tabela 01, ao analisar o desempenho dos métodos separadamente para cada região (comparação horizontal das métricas), o que permite avaliar o poder de generalização dos modelos, primeiramente foi avaliado o MAPE dentro da amostra com o MAPE fora da amostra. Com exceção das regiões Centro-Oeste (MBJ) e Sul (MAE e MBJ), em todas as demais regiões os métodos avaliados apresentaram um erro de previsão fora da amostra menor do que dentro da amostra, ou seja, apresentaram um bom poder de generalização, o que significa que preveem melhor a realidade mais recente. Apesar disso, os valores do MAPE, tanto para o MAE quanto para o MBJ, se encontram baixos em todas as regiões, seja dentro ou fora da amostra, indicando baixo percentual de erro para mais ou para menos ao se projetar o próximo período (mês).

Tabela 1- Resultado da Competição entre os Métodos de Previsão

Região	Dentro da Amostra (<i>In sample</i>)			Fora da Amostra (<i>Out of Sample</i>)			
	Modelo	R ² _{ajus} (%)	MAPE (%)	MAPE (%) H=1 N=12	MAPE ACUM (%)	GMRAE H=1 N=12	GMRAE ACUM
Centro-oeste	MAE	99,73	2,21	2,20	2,30	0,61	0,65
	MBJ	99,84	2,13	2,20	1,90	0,84	0,57
Nordeste	MAE	99,68	1,77	1,30	2,40	0,55	0,87
	MBJ	99,79	1,74	1,40	2,20	0,79	0,81
Norte	MAE	99,79	2,11	1,30	1,50	0,13	0,25
	MBJ	99,91	2,01	1,50	2,40	0,41	0,62
Sudeste	MAE	99,12	2,35	1,80	2,90	1,52	1,75
	MBJ	99,26	2,20	1,50	1,70	1,08	1,05
Sul	MAE	99,68	1,91	2,70	4,00	1,03	0,63
	MBJ	99,83	1,83	1,90	2,00	0,67	0,26

Fonte: Elaboração própria. Nota: H = Horizonte; N = Quantidade de previsões. ACUM = Resultado acumulado das 78 previsões fora da amostra.

Para a competição entre os métodos, é feita a leitura dos dados seguindo a orientação das colunas (comparação vertical das métricas). Observa-se que, para as previsões de todas as cinco regiões, o Método de Box & Jenkins (MBJ) apresentou um R² ajustado um pouco maior do que o Método de Amortecimento Exponencial (MAE), ou seja, suas previsões obtiveram um poder de explicação superior.

A observação do MAPE dentro da amostra corrobora o fato que o Método de Box & Jenkins (MBJ) obteve o melhor desempenho ao apresentar os menores valores para todas as regiões. Além disso, pode-se afirmar que o MBJ, como analisado anteriormente, apresentou bom poder de generalização, uma vez que o seu MAPE fora da amostra foi menor do que o MAPE dentro da amostra para as regiões Norte, Nordeste e Sudeste. Já para as regiões Centro-oeste e Sul, o poder de generalização do MBJ não se mostra tão prejudicado, tendo em vista que o MAPE *in sample* foi superior ao *out of sample* em apenas 0,07 pontos percentuais em ambas as regiões.

Com relação à comparação com o método ingênuo (análise do GMRAE), ambos os modelos apresentaram resultados satisfatórios (GMRAE menor do que 1), com exceção da região Sudeste, onde MAE e MBJ apresentaram valores de GMRAE superiores a 1, o que indica

que ambos os modelos foram menos eficientes que o modelo ingênuo (*naive*), o qual utiliza como previsor o último dado da série. O mesmo aconteceu para o MAE da região Sul.

Com base nestes resultados, o MBJ foi considerado como método vencedor, pois apresenta melhor desempenho preditivo (maior poder de explicação e menor erro) tanto dentro quanto fora da amostra. Além disto o desempenho é melhor tanto para as previsões 1 passo à frente ($H = 1$) quanto no acumulado das 78 previsões.

Na seção seguinte serão apresentados os modelos de Box & Jenkins reestimados após a reinserção dos dados que foram retirados da amostra total. Isto significa que, após a atualização paramétrica, o MBJ será aplicado para calcular as previsões do consumo de energia elétrica por região no Brasil.

4.3 EQUAÇÕES DE PREVISÃO

Uma vez definido o Método de Box & Jenkins (MBJ) como modelo vencedor, serão apresentadas a seguir as equações de previsão finais resultantes da atualização paramétrica. Foram calculados também o poder de explicação e o MAPE para estas equações finais. Estas foram as equações utilizadas para calcular o consumo de energia elétrica nas regiões brasileiras. Os resultados podem ser observados na Tabela 02.

Vale destacar que, devido às condições de não estacionaridade de todas as séries, foi necessário aplicar a operação de diferença e também a transformação logarítmica em todas as séries. Pode-se observar também que foram estimados modelos Box & Jenkins com sazonalidade (equação 3.19).

Vê-se que os modelos têm poder de explicação com um R^2 ajustado em torno de 99% e apresentam erro absoluto percentual médio em torno de 2%. Isto significa que o MBJ explica em torno de 99% da evolução do consumo de energia elétrica nas regiões brasileiras e os modelos erram em média, para baixo ou para cima, certa de 2% ao projetar o próximo mês.

Tabela 2- Equações de previsão para o consumo de energia elétrica nas regiões

Região	MBJ	Equação de previsão	R ² adj (%)	MAPE (%)
Centro-oeste	ARIMA(0,1,1)*(1,0,1)	$(1 - 0,9993B^{12})\ln(Z_t) = (1 - 0,8963B^{12}) (1-0,3896B)a_t$	99,85	2,13
Nordeste	ARIMA(0,1,1)*(1,0,1)	$(1 - 0,9995B^{12})\ln(Z_t) = (1 - 0,9301B^{12}) (1-0,1471B)a_t$	99,80	1,74
Norte	ARIMA(1,1,0)*(1,0,1)	$(1-0,9978B^{12})(1 + 0,2007B)(1-B)\ln(Z_t) = (1-0,8685B^{12}) a_t$	99,91	1,99
Sudeste	ARIMA(1,1,0)*(1,0,2)	$(1-0,9907B^{12})(1+0,3602B)(1-B)\ln(Z_t) = (1-0,7342B^{12}-0,1606B^{24}) a_t$	99,27	2,18
Sul	ARIMA(1,1,1)*(1,0,1)	$(1-0,9902B^{12})(1-0,5661B)(1-B)\ln(Z_t) = (1-0,8008B^{12}) (1-0,8768B)a_t$	99,84	1,83

Fonte: Elaboração própria. Nota: Todas as estruturas ARIMA foram identificadas após transformação logarítmica nas séries de consumo de energia elétrica.

O próximo passo da modelagem consiste em realizar o teste de Ljung-Box para verificar a fidedignidade do modelo no que concerne à estrutura de autocorrelação dos erros. De acordo com a tabela 3, todos os p-valores encontrados são superiores a 0,95, o que levaria, a princípio à rejeição da hipótese nula dos erros descorrelatados. Entretanto, conforme apresentado na seção 3.3, o teste precisa ser corroborado com a análise gráfica do correlograma dos erros que podem ser encontradas na Figura 03.

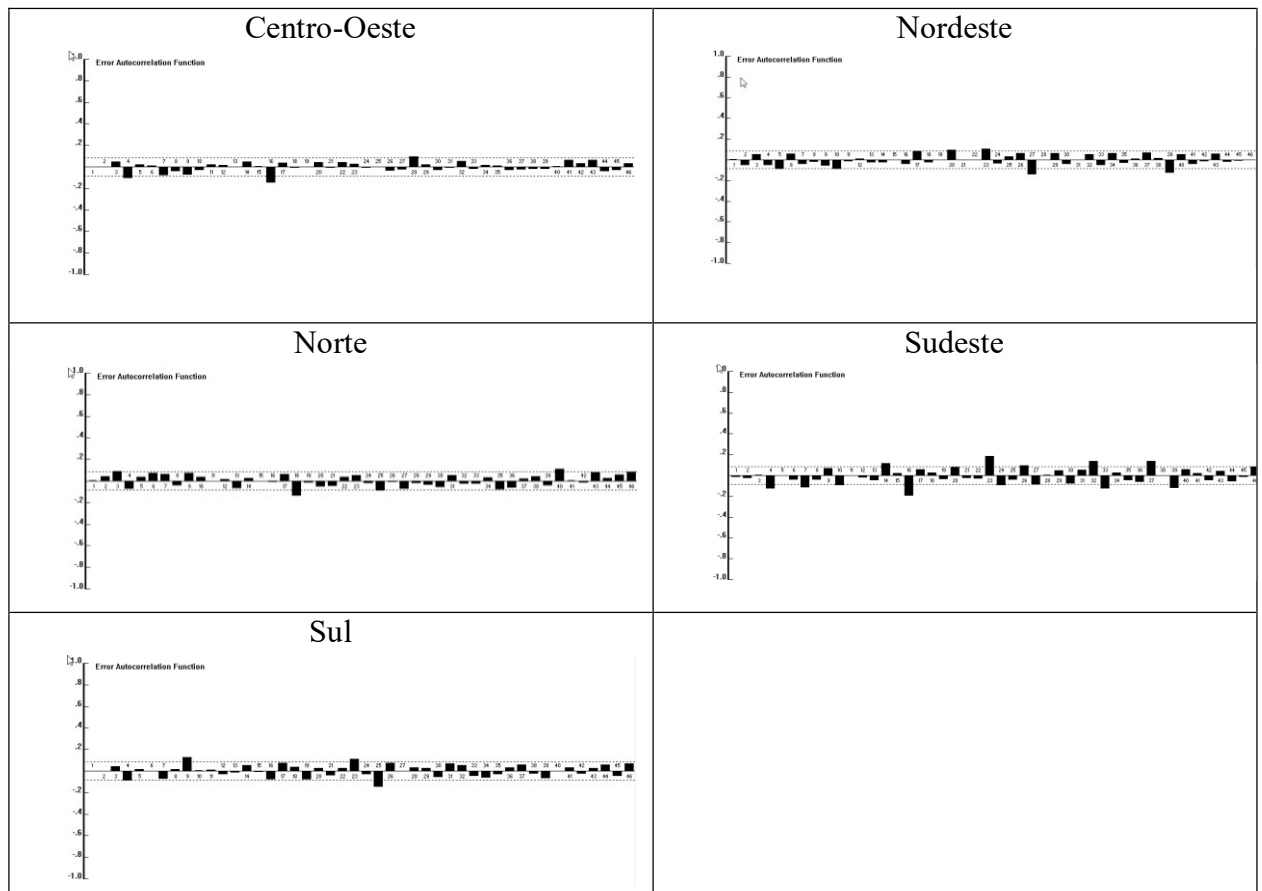
Tabela 3- Teste de Ljung-Box por região

Região	p-valor
Centro-oeste	0,9749
Nordeste	0,9636
Norte	0,9950
Sul	0,9795
Sudeste	1,0000

Fonte: Elaboração própria.

Ao se observar os gráficos de autocorrelação dos erros (figura 3) é possível assumir que os resíduos possuem autocorreção fraca, ou praticamente nula, dada a permanência dos mesmos dentro dos limites entre -0,2 e 0,2 nos gráficos.

Figura 3- Gráficos de autocorrelação dos erros por região

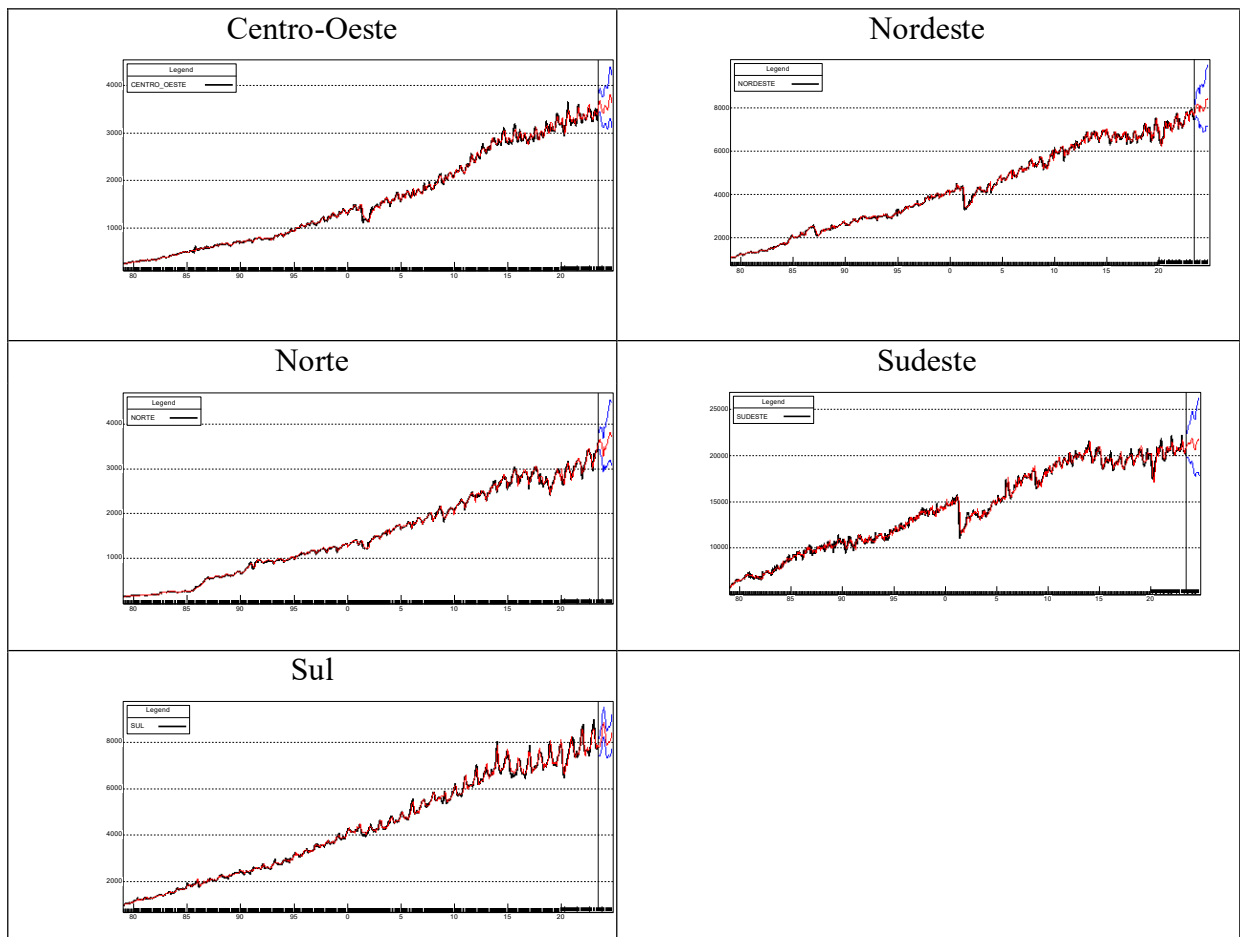


Fonte: Elaboração própria

4.4 PREVISÕES

A figura 04 a seguir apresenta as projeções do consumo de energia elétrica em cada uma das regiões calculadas pelo Método de Box & Jenkins (MBJ), para as regiões Centro-Oeste, Nordeste, Norte, Sudeste e Sul do Brasil em GWh para o ano de 2023 (setembro a dezembro) e 2024.

**Figura 4 - Consumo de energia (em GWh) – período de 1979 a 2024
Valores reais, ajustados e previsões com intervalo de confiança (IC) de 95%**



Fonte: Elaboração própria. Nota: — Valores reais — Valores projetados — IC de 95%

Já as tabelas de 4 a 8 contêm as previsões calculadas para cada uma das regiões no período de setembro de 2023 até dezembro de 2024. Vale ressaltar que além do valor da previsão (cenário “esperado”), há também os valores referentes ao limite superior (cenário “otimista”) e limite inferior (cenário “pessimista”) do intervalo de confiança de 95%.

**Tabela 4- Valores da Previsão do Consumo de energia elétrica (em GWh) –
Intervalo de Confiança de 95% - região Centro-Oeste**

Mês	Limite Inferior	Previsão	Limite superior
2023-09	3428	3633	3849
2023-10	3449	3691	3951
2023-11	3339	3604	3891
2023-12	3216	3499	3807
2024-01	3130	3430	3759
2024-02	3103	3422	3775
2024-03	3169	3517	3903
2024-04	3211	3584	4002
2024-05	3170	3559	3995
2024-06	3097	3495	3944
2024-07	3068	3479	3947
2024-08	3176	3620	4126
2024-09	3285	3768	4322
2024-10	3320	3829	4416
2024-11	3225	3739	4335
2024-12	3115	3630	4229

Fonte: Elaboração própria.

**Tabela 5 - Valores da Previsão do Consumo de energia elétrica (em GWh) –
Intervalo de Confiança de 95% - região Nordeste**

Mês	Limite Inferior	Previsão	Limite superior
2023-09	7407	7772	8156
2023-10	7598	8095	8623
2023-11	7519	8107	8742
2023-12	7479	8150	8881
2024-01	7385	8122	8933
2024-02	7009	7775	8624
2024-03	7240	8094	9048
2024-04	7084	7977	8984
2024-05	7063	8008	9081
2024-06	6853	7821	8927
2024-07	6822	7835	8998
2024-08	6889	7959	9195
2024-09	6905	8032	9341
2024-10	7147	8364	9789
2024-11	7115	8378	9864
2024-12	7111	8421	9973

Fonte: Elaboração própria.

**Tabela 6 - Valores da Previsão do Consumo de energia elétrica (em GWh) –
Intervalo de Confiança de 95% - região Norte**

Mês	Limite Inferior	Previsão	Limite superior
2023-09	3412	3606	3810
2023-10	3424	3675	3943
2023-11	3308	3599	3916
2023-12	3252	3580	3940
2024-01	3114	3463	3852
2024-02	2920	3279	3682
2024-03	3083	3492	3956
2024-04	2998	3424	3910
2024-05	3074	3538	4072
2024-06	3052	3538	4101
2024-07	3103	3623	4229
2024-08	3179	3736	4390
2024-09	3171	3758	4454
2024-10	3204	3827	4570
2024-11	3115	3748	4510
2024-12	3077	3728	4518

Fonte: Elaboração própria.

**Tabela 4- Valores da Previsão do Consumo de energia elétrica (em GWh) –
Intervalo de Confiança de 95% - região Sudeste**

Mês	Limite Inferior	Previsão	Limite superior
2023-09	19750	20976	22278
2023-10	19747	21211	22782
2023-11	19617	21361	23261
2023-12	19258	21191	23318
2024-01	19138	21267	23634
2024-02	18977	21277	23855
2024-03	19378	21906	24765
2024-04	19028	21679	24698
2024-05	18289	20989	24088
2024-06	17923	20713	23936
2024-07	17649	20531	23884
2024-08	17960	21026	24615
2024-09	18073	21391	25318
2024-10	18111	21618	25805
2024-11	18085	21777	26221
2024-12	17746	21542	26150

Fonte: Elaboração própria.

Tabela 8 - Valores da Previsão do Consumo de energia elétrica (em GWh) – Intervalo de Confiança de 95% - região Sul

Mês	Limite Inferior	Previsão	Limite superior
2023-09	7399	7757	8132
2023-10	7382	7818	8280
2023-11	7515	7998	8512
2023-12	7703	8222	8777
2024-01	8043	8604	9205
2024-02	8201	8788	9418
2024-03	8262	8867	9516
2024-04	7867	8455	9086
2024-05	7440	8007	8616
2024-06	7289	7854	8462
2024-07	7353	7932	8557
2024-08	7446	8042	8686
2024-09	7361	7976	8642
2024-10	7387	8022	8713
2024-11	7531	8195	8918
2024-12	7722	8417	9175

Fonte: Elaboração própria.

Na tabela 09 a seguir é possível observar, em termos anuais, o consumo de energia projetado em cada região e a variação percentual anual.

Tabela 09: Consumo de energia elétrica anual (GWh) por região e variação percentual

	CO	Var(%)	NE	Var(%)	NO	Var(%)	SE	Var(%)	S	Var(%)
2017	35.217	-	79.087	-	34.488	-	231.433	-	84.813	-
2018	36.040	2,3%	80.800	2,2%	32.522	-5,7%	235.871	1,9%	86.405	1,9%
2019	38.109	5,7%	82.847	2,5%	33.077	1,7%	238.444	1,1%	88.306	2,2%
2020	38.893	2,1%	81.099	-2,1%	34.679	4,8%	231.780	-2,8%	87.494	-0,9%
2021	39.706	2,1%	86.847	7,1%	36.598	5,5%	244.474	5,5%	92.564	5,8%
2022	40.550	2,1%	88.198	1,6%	38.107	4,1%	248.067	1,5%	94.715	2,3%
2023*	41.466	2,3%	93.759	6,3%	40.932	7,4%	251.221	1,3%	97.413	2,8%
2024*	43.072	3,9%	96.786	3,2%	43.154	5,4%	255.715	1,8%	99.161	1,8%

Fonte: Elaboração própria. CO: Centro-Oeste; NE: Nordeste; NO: Norte; SE: Sudeste; S: Sul. Nota: *Valores (setembro a dezembro de 2023 e janeiro a dezembro de 2024) calculados pelo MBJ.

Observando a tabela 09, vê-se que é projetado um crescimento médio do consumo de energia elétrica no período de 2023 a 2024 de 3,1% para o Centro-Oeste, 4,8% para o Nordeste, 6,4% para o Norte, 1,5% para o Sudeste e 2,3% para o Sul. Este cálculo foi feito considerando o cenário esperado (valor da previsão calculado pelas equações de previsão), mas obviamente poderia ser feito também para os cenários “pessimista” e “otimista”.

Considerando que, alguns estudos¹⁷ utilizam o consumo de energia elétrica como proxy do nível de atividade econômica, e que os modelos estimados neste trabalho monográfico estão projetando um consumo crescimento de energia elétrica por região, poder-se-ia inferir sobre possíveis tendências da atividade econômica no Brasil neste horizonte de curto prazo, ou seja, até 2024. Este cenário de crescimento converge com previsões que estão sendo feitas para a economia brasileira. O IPEA, por exemplo, recentemente revisou a previsão do PIB de 2,3% para 3,3% em 2023 e mantém em 2,0% a estimativa para 2024¹⁸.

¹⁷ Como Mathias et all (2015).

¹⁸ Ver IPEA (2023). <https://www.ipea.gov.br/portal/categorias/45-todas-as-noticias/noticias/14009-ipea-revisa-a-previsao-do-pib-de-2-3-para-3-3-em-2023-e-mantem-em-2-0-a-estimativa-para-2024>.

5. CONCLUSÃO

O setor de energia elétrica, pode ser considerado um setor chave na economia, uma vez que o nível de consumo energia elétrica é considerada um dos principais indicadores do desenvolvimento econômico e do nível da qualidade de vida de uma nação. Este trabalho monográfico, teve como objetivo principal modelar o consumo de energia por região e realizar as suas previsões de consumo no curto prazo.

Para alcançar tal objetivo, fez-se uso da competição entre o Método de Amortecimento Exponencial (MAE) e o Método de Box & Jenkins (MBJ) a fim de determinar o método mais eficiente para realizar as previsões. Após as comparações das métricas resultantes dos processos de análises *in-sample* e *out-of-sample* com análise recursiva fora da amostra (*out-of-sample rolling evaluation*), determinou-se que o Método de Box & Jenkins foi o método vencedor para se calcular as previsões do consumo de energia elétrica por região.

Foram obtidas previsões mensais para o horizonte de setembro de 2023 a dezembro de 2024. Viu-se que uma das vantagens de se trabalhar com modelos estatístico-matemáticos consiste em se obter não apenas um número, a previsão, mas um intervalo de confiança que possui determinada probabilidade de conter o valor da previsão.

Os modelos estimados projetaram um crescimento médio do consumo de energia elétrica no período de 2023 a 2024 de 3,1% para o Centro-Oeste, 4,8% para o Nordeste, 6,4% para o Norte, 1,5% para o Sudeste e 2,3% para o Sul. Este cálculo foi feito considerando o cenário esperado (valor da previsão calculado pelas equações de previsão), mas obviamente poderia ser feito também para os cenários “pessimista” e “otimista”.

Uma vez que a energia elétrica é um insumo demandado pelos setores da economia, a maior compreensão das dinâmicas do setor aliada ao emprego de modelos preditivos bem estruturados fornece aos formuladores de políticas públicas e aos demais agentes econômicos informações confiáveis para o planejamento e operação do setor elétrico. Com a estimação do intervalo de confiança, é possível traçar cenários diversos para o consumo.

Acredita-se que esta monografia atingiu o objetivo de estudar as características do setor elétrico brasileiro, bem como entender a dinâmica das séries de consumo de energia elétrica por região. A modelagem dos dados de consumo indexados no tempo, a estimação dos modelos bem como o cálculo das previsões, permitiu verificar que, a princípio, haverá uma tendência de crescimento do consumo de energia elétrica regional no Brasil.

Como sugestão de propostas de trabalhos futuros, poder-se-ia buscar compreender o impacto de outras variáveis como, por exemplo, fenômenos naturais de larga escala, como as crises climáticas, no consumo das regiões do Brasil, uma vez que estas apresentam características geográficas únicas. Para a realização dessa análise, propõe-se a utilização de métodos que utilizam outras variáveis que não só as variáveis de interesse, as quais se deseja projetar. O Método de Regressão Dinâmica¹⁹, por exemplo, permite capturar a elasticidade da variável de interesse com outras variáveis explicativas, possibilitando a análise do grau de sensibilidade entre as variáveis, permitindo realizar avaliações de impacto. A estimação destas elasticidades e o estudo de eventos pode permitir a construção de cenários diversos para o consumo de cada região.

¹⁹ GOODRICH (1989).

REFERÊNCIAS

ASSIS, VINÍCIUS FERNANDES DE. CONSTRUÇÃO DE UM MODELO DE PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NO BRASIL: ANÁLISE PARA O SETOR COMERCIAL (2017-2018). Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2017.

BAJAY, Sergio Valdir. Evolução do planejamento energético na última década e desafios pendentes. **Revista Brasileira de Energia**, v. 19, n. 1, p. 255-266, 2013.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis, Forecasting and Control**. San Francisco, Holden-Day, 1994.

CÂNDIDO, LUCAS FARIA. MODELO DE PREVISÃO DA PRODUÇÃO DO SETOR DE ENERGIA EÓLICA NACIONAL (2017 - 2018). Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2017.

CHAIN, DIEGO REIS. UM ESTUDO DAS ELASTICIDADES TARIFA E RENDA PARA O CONSUMO DE ENERGIA ELÉTRICA NO SETOR INDUSTRIAL NO BRASIL (1990-2018) ATRAVÉS DO MODELO DE REGRESSÃO DINÂMICA. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2019.

DUDEWICZ, E.J.; MISHRA, S.N.. *Modern Mathematical Statistics*. Wiley, 1988.

EPE. **Relatório Síntese 2022**: ano base 2021. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-675/topico-631/BEN_S%C3%ADntese_2022_PT.pdf>. Acesso em: 12 de abril. 2023

FARIA, VITOR FERRAZ. PLANEJAMENTO ENERGÉTICO: UM MODELO DE PREVISÃO PARA O CONSUMO TOTAL DE ENERGIA ELÉTRICA NO BRASIL. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2019.

FERREIRA, ROGÉRIO PIRES. UM MODELO DE PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NO SETOR INDUSTRIAL BRASILEIRO (2018-2019). Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2018.

GOODRICH, R.L.. *Applied Statistical Forecasting*, Belmont, Business Forecast Systems, 1989.

GOODRICH, R.L.; STELLWAGEN, E.A.. *Forecast Pro for Windows*. Business Forecast Systems, 1999.

HARVEY, Andrew C.; PETERS, Simon. Estimation procedures for structural time series models. **Journal of forecasting**, v. 9, n. 2, p. 89-108, 1990

IPEA. <https://www.ipea.gov.br/portal/categorias/45-todas-as-noticias/noticias/14009-ipea-revisa-a-previsao-do-pib-de-2-3-para-3-3-em-2023-e-mantem-em-2-0-a-estimativa-para-2024>. Acesso em 21 de novembro. 2023.

IPEADATA. Base de dados Consumo anual de energia elétrica – região Norte (N) (1979-2023). Brasil, 2023.

IPEADATA. Base de dados Consumo anual de energia elétrica – região Nordeste (NE) (1979-2023). Brasil, 2023

IPEADATA. Base de dados Consumo anual de energia elétrica – região Centro-Oeste (CO) (1979-2023). Brasil, 2023

IPEADATA. Base de dados Consumo anual de energia elétrica – região Sul (S) (1979-2023). Brasil, 2023

IPEADATA. Base de dados Consumo anual de energia elétrica – região Sudeste (SE) (1979-2023). Brasil, 2023

LORENZO, Helena Carvalho De. O setor elétrico Brasileiro: Passado e Futuro. **Perspectivas** v. 24/25, n. 20, p. 147–170 , 2002.8577531007; 9788577531004.

MATHIAS, J. F. C. M; CASTRO, N. J. DE; SILVA, SILVA, S. DE O.; BRANDÃO, R.. ATIVIDADE ECONÔMICA E CONSUMO DE ENERGIA ELÉTRICA NO BRASIL: UMA ABORDAGEM BASEADA NA PESQUISA INDUSTRIAL ANUAL DO IBGE. Revista Brasileira de Energia. v. 21. No. 1. 2015.

MATTOS, Ana Paula de Oliveira. Modelo de Previsão do Consumo Residencial de Energia Elétrica no Brasil (2017-2018). Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2017.

MENDES JUNIOR, EDIMAR RONALDE. ESTUDO DA CAUSALIDADE ENTRE GERAÇÃO DE ENERGIA ELÉTRICA E CRESCIMENTO ECONÔMICO NA ECONOMIA BRASILEIRA. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2018.

MIRANDA, Gabriel Mendes. UM ESTUDO DAS ELASTICIDADES TARIFA E RENDA PARA O CONSUMO DE ENERGIA ELÉTRICA TOTAL NO BRASIL ATRAVÉS DO MODELO DE REGRESSÃO DINÂMICA. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2019.

MME. **Conheça as instituições do setor elétrico brasileiro e as competências de cada uma.** Disponível em: <<https://www.gov.br/mme/pt-br/assuntos/noticias/conheca-as-instituicoes-do-setor-eletrico-brasileiro-e-as-competencias-de-cada-uma>>. Acesso em: 12 de abril. 2023.

MME. **Matriz elétrica brasileira apresenta expansão de 2.746 MW no primeiro trimestre de 2023.** Disponível em: <<https://www.gov.br/mme/pt-br/assuntos/noticias/matriz-eletrica-brasileira-apresenta-expansao-de-2-746-mw-no-primeiro-trimestre-de->

SILVA, Bruno Gonçalves da. **Evolução do setor elétrico brasileiro no contexto econômico nacional: uma análise histórica e econométrica de longo prazo.** 2011, 162 f. Dissertação (Mestrado em Energia) – Programa de Pós-Graduação em Energia da Universidade de São Paulo, São Paulo, 2011.

SILVA, Vinicius William Oliveira da. **Mensuração dos impactos da pandemia no consumo de energia elétrica no Brasil e nas regiões via método de amortecimento exponencial com modelagens em múltiplos níveis.** 2022. 53 f. TCC (Graduação) - Curso de Ciências Econômicas, Departamento de Ciências Econômicas, Universidade Federal de Juiz de Fora, Juiz de Fora, 2022.

SOUZA, Fabio Olivato de. **MÉTODO DE AMORTECIMENTO EXPONENCIAL COM ABORDAGEM BOTTOM-UP E TOP-DOWN PARA PREVISÃO DO CONSUMO TOTAL DE ENERGIA ELÉTRICA NO BRASIL PARA 2019.** Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2019.

TAVARES, Mateus Rodrigues Gonçalves. **UM ESTUDO DAS ELASTICIDADES TARIFA E RENDA PARA O CONSUMO DE ENERGIA RESIDENCIAL NO BRASIL (1994 A 2013) ATRAVÉS DO MODELO DE REGRESSÃO DINÂMICA.** Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2018.

VIEIRA, Braulio Santos. **Modelagem do Consumo de Energia Elétrica no Brasil através da Metodologia do Box & Jenkins.** 2008. 60 f. TCC (Graduação) - Curso de Ciências Econômicas, Departamento de Ciências Econômicas, Universidade Federal de Juiz de Fora, Juiz de Fora, 2008.

VITOR, JOÃO FRANCISCO MACHADO. **MENSURAÇÃO DO IMPACTO DA COVID-19 NO CONSUMO DE ENERGIA ELÉTRICA NO SETOR INDUSTRIAL ATRAVÉS DA ANÁLISE DE REGRESSÃO DINÂMICA.** Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. 2021.

ZANINI, A. **Modelos de Previsão para séries temporais. Material Didático.** Juiz de Fora/MG, 2023.