

UNIVERSIDADE FEDERAL DE JUIZ DE FORA  
FACULDADE DE ECONOMIA

FELIPE DE SOUZA OLIVEIRA

**MÉTODOS LINEARES E NÃO-LINEARES APLICADOS À PREVISÃO DO  
CONSUMO DE ENERGIA ELÉTRICA NO BRASIL**

JUIZ DE FORA - MG  
2022

FELIPE DE SOUZA OLIVEIRA

**MÉTODOS LINEARES E NÃO-LINEARES APLICADOS À PREVISÃO DO  
CONSUMO DE ENERGIA ELÉTRICA NO BRASIL**

Monografia apresentado ao curso de Ciências  
Econômicas da Universidade Federal de Juiz de  
Fora, como requisito para obtenção do título de  
bacharel em Ciências Econômicas.

Orientador: Alexandre Zanini

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

De Souza Oliveira, Felipe.

MÉTODOS LINEARES E NÃO-LINEARES APLICADOS À PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NO BRASIL / Felipe De Souza Oliveira. -- 2022.

41 p. : il.

Orientador: Alexandre Zanini  
Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Juiz de Fora, Faculdade de  
Economia, 2022.

1. Modelos Lineares. 2. Modelos não-lineares. 3.  
Consumo de energia elétrica.. 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 12/12/2022, a Banca Examinadora, composta pelos professores

1 – Alexandre Zanini - orientador; e

2 – Flaviane Souza Santiago,

reuniu-se para avaliar a monografia do acadêmico **FELIPE DE SOUZA OLIVEIRA**, intitulada: **MÉTODOS LINEARES E NÃO-LINEARES APLICADOS À PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NO 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.



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 12/12/2022, às 21:37, 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 **Flaviane Souza Santiago, Professor(a)**, em 13/12/2022, às 16:05, 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](http://www2.ufjf.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **1075673** e o código CRC **24B3AC74**.

## RESUMO

Esse trabalho contribui com um estudo comparativo de desempenho de metodologias preditivas de séries temporais na previsão do consumo total mensal de energia elétrica brasileiro. Foram aplicados os Métodos de Amortecimento Exponencial, Box & Jenkins e Redes Neurais Artificiais. Os desempenhos dos modelos foram quantificados por meio da métrica *Root Mean Squared Error* (RMSE). Os resultados mostram o melhor resultado preditivo do modelo de RNA em relação aos outros.

Palavras chaves: Modelos Lineares, Modelos não-lineares, Consumo de energia elétrica.

## **ABSTRACT**

This work contributes to a comparative study of the performance of time series predictive methodologies in forecasting the monthly consumption of electricity in the Brazilian market. The models used were Exponential Smoothing, Box & Jenkins and Artificial Neural Networks. The performance of the models was quantified through Root Mean Squared Error (RMSE) metric. The results show the prediction superiority of Artificial Neural Networks model in relation to the others.

Keywords: Linear Models, Nonlinear Models, Electric Power Consumption.

## LISTA DE FIGURAS

Figura 1 - Distribuição Da Matriz Energética No Brasil.....	13
Figura 2 - Evolução da Capacidade Instalada no SIN .....	15
Figura 3 - As Subdivisões do SIN .....	16
Figura 4 - Neurônio biológico. ....	25
Figura 5 - O Processo de "Feedforward Propagation". ....	28
Figura 6 - Consumo Mensal Total de Energia Elétrica (GWh) - 1976-2022 .....	30
Figura 7 - Consumo Mensal Total de Energia Elétrica (GWh) - 2015-2022 .....	31
Figura 8 - Previsão do Consumo de Energia Elétrica no Brasil - MAE.....	33
Figura 9 - Previsão do Consumo de Energia Elétrica no Brasil - MBJ.....	34
Figura 10 - Previsão do Consumo de Energia Elétrica no Brasil - RNA .....	35

**LISTA DE TABELAS**

Tabela 1 - Fatores Sazonais .....	32
Tabela 2 - Previsão do Consumo de Energia Elétrica no Brasil (GWh) – MAE .....	35
Tabela 3 - Previsão do Consumo Total de Energia Elétrica (GWh) - MBJ .....	36
Tabela 4 - Previsão do Consumo de Energia Elétrica no Brasil (GWh) - RNA.....	37
Tabela 5 - Consumo Total de Energia Elétrica no Brasil (GWh) e Variação % .....	38
Tabela 6 - RMSE (Root Mean Square Error) .....	38
Tabela 7 - Comparação da Previsão Anual RNA X EPE (GWh).....	39



## **LISRA DE SIGLAS E ABREVIATURAS**

ANEEL	Agência Nacional de Energia Elétrica
BRICS	Brasil, Rússia, Índia, China e África do Sul
EPE	Empresa de Pesquisa Energética
Gwh	Gigawatt hours
MAE	Método de Amortecimento Exponencial
MBJ	Método Box & Jenkins
ONS	Operador Nacional Do Sistema Elétrico
RMSE	Root Mean Square Error
RNA	Redes Neuras artificiais
SIN	Sistema Interligado Nacional

**SUMÁRIO**

1.	INTRODUÇÃO.....	11
2.	O SISTEMA ELÉTRICO BRASILEIRO .....	13
2.1.	O Sistema Interligado Nacional.....	13
2.2	Agência Nacional de Energia Elétrica.....	16
2.3.	Revisão Da literatura para a modelagem do Setor Elétrico .....	17
3.	METODOLOGIA E BASE DE DADOS.....	19
3.1	Série Temporal X Processo Estocástico .....	19
3.2	Competição de modelos .....	20
3.3	Método Amortecimento Exponencial (MAE) .....	21
3.4	Método de Box & Jenkins (MBJ).....	23
3.5	Redes Neurais Artificiais (RNA).....	25
3.6	BASE DE DADOS:.....	30
4.	RESULTADOS .....	32
5.	CONCLUSÃO.....	40
	REFERÊNCIAS BIBLIOGRÁFICAS .....	42

## 1. INTRODUÇÃO

O consumo de energia está diretamente relacionado ao desenvolvimento da civilização humana. Desde os primórdios com a descoberta do manejo do fogo, até a extração da força atômica, os seres humanos se valem das forças da natureza para gerar o desenvolvimento da sociedade, e com a evolução dessas, são demandadas novas fontes energéticas. Ao longo das últimas décadas, o desenvolvimento de diversos países, em especial os emergentes, foi proporcionado por um substancial aumento no consumo de energia elétrica no intuito de suprir o ritmo de crescimento dos processos produtivos (MENDES, 2014).

Conforme demonstrado por Fernandes (2014), a energia elétrica é um serviço público de competência da União devido ao fato de constituir um insumo de severa importância para diversos setores da economia nacional. Ademais, no atual estado de desenvolvimento social, esse serviço não só afeta os fatores econômicos, mas também o bem estar da população de uma forma geral (DE CASTRO; ROSENTAL, 2016).

O setor de energia elétrica no Brasil apresenta características distintas no que diz respeito à forma pela qual a matriz energética é composta. Por um lado, grande parte da geração de energia se dá por fontes limpas, principalmente a geração por meio de hidrelétricas. Por outro, o grande custo socioambiental na construção e manutenção desse tipo de geração de energia, atrelado a um regime de chuvas irregular dos últimos anos é motivo de preocupações dos formuladores de política pública (MENDES, 2014).

Assim, vê-se oportuna a utilização de procedimentos e métodos estatísticos na análise de dados desse setor, não só no sentido de identificar padrões de comportamento ao longo do tempo, como também a realização de previsões para valores futuros (TIDRE *et al*, 2013).

O objetivo deste trabalho é então estudar e aplicar métodos de análise de séries de tempo sobre o consumo total de energia elétrica no Brasil. Serão aplicados dois métodos lineares e um método não-linear.

Dessa forma, este trabalho procura agregar a literatura na estimação de um modelo de séries temporais para o consumo mensal de energia elétrica total, utilizando os dados no período de 2015 a 2022, além de realizar a previsão para o ano de 2023. Para esse fim, serão utilizados modelos de séries temporais que utilizam apenas a própria variável consumo, ou seja, todos os

métodos apresentam caráter autoprojetivo. Serão utilizados o Método de Amortecimento Exponencial (MAE)<sup>1</sup>, Método de Box & Jenkins (MBJ)<sup>2</sup> e as Redes Neurais Artificiais (RNA)<sup>3</sup>.

O presente trabalho está estruturado da seguinte forma. Além da presente introdução, no capítulo dois é feita uma exposição sucinta do sistema elétrico no Brasil; o capítulo três apresenta a metodologia a ser empregada junto com a base de dados utilizada; já o capítulo quatro são expostos e analisados os resultados obtidos e, no final, podem ser vistas as conclusões mais relevantes do estudo.

---

<sup>1</sup> Montgomery (1990).

<sup>2</sup> Box & Jenkins (1994).


<sup>3</sup> Haykin (1998).

## 2. O SISTEMA ELÉTRICO BRASILEIRO

### 2.1. O Sistema Interligado Nacional

No Brasil, a produção e distribuição de energia elétrica se dá pelo Sistema Interligado Nacional (SIN), esse é composto pelas instalações e equipamentos que fornecem o suprimento de energia elétrica nas diversas regiões do país que estão conectadas eletricamente (DE ALMEIDA, 2022). Como mostrado Figura 1, as três principais fontes geradoras de energia no Brasil são: hidráulicas com uma participação de 62,62%, térmica (gás, óleo e carvão) desempenhando 21,69%, e eólica fornecendo 11,92%.

Figura 1 - Distribuição Da Matriz Energética No Brasil



Fonte: (ONS,2022)


É válido ressaltar que há no Brasil uma parcela significativa da geração de energia feita por fontes renováveis. A título de comparação, nos países participantes dos BRICS (Brasil, Rússia, Índia, China e África do Sul) o carvão mineral compõe 50% da matriz energética, seguido do petróleo, gerador de 20% de toda a energia elétrica produzida nos cinco países. No Brasil, as fontes de energia renováveis representam 82,5%. Caso considerada a produção de

energia renovável mundial, o Brasil produz 7,2% do total gerado (MINISTÉRIO DA ECONOMIA, 2022)

No que se refere à capacidade de produção do SIN, a fonte primária é dada por meio das usinas hidrelétricas, que estão localizadas em inúmeras bacias hidrográficas ao longo de todo o território nacional. Em segundo lugar, estão as usinas térmicas que, no geral, localizam-se próximas aos principais centros consumidores. Ademais, as usinas térmicas desempenham um papel fundamental para a segurança do SIN, pois são utilizadas quando as condições hidrológicas vigente estão desfavoráveis, possibilitando a preservação dos estoques de água nos reservatórios das usinas elétricas. O terceiro tipo mais comum de geração de energia é por meio de fontes renováveis limpas (eólica e solar), sendo que essas apresentaram um forte crescimento na participação na geração da energia no país nos últimos anos estando concentradas, principalmente, nas regiões Nordeste e Sul (ONS, 2022).

Conforme mostrado na Figura 2, a previsão é de que a participação da energia eólica e solar continuem aumentando no futuro, sendo que, para 2026, os números previstos são: 15% e 6,9%, respectivamente. É válido destacar que, em ambos os casos, o Brasil possui um significativo potencial de geração de energia que ainda pode ser aproveitado. No caso eólico, a produção pode chegar a 20,38% em 2050 (CUNHA *et al*, 2019). No que tange ao potencial fotovoltaico, segundo Martins *et al* (2017), o Brasil possui um potencial fotovoltaico médio de geração de 1450 kWh/por ano, a título de comparação, as regiões brasileiras com menos incidência solar conseguem gerar mais energia que o local mais ensolarado da Alemanha. Em projeções para 2050, a participação da energia fotovoltaica na matriz energética brasileira pode atingir os 9,26% (CUNHA *et al*, 2019).

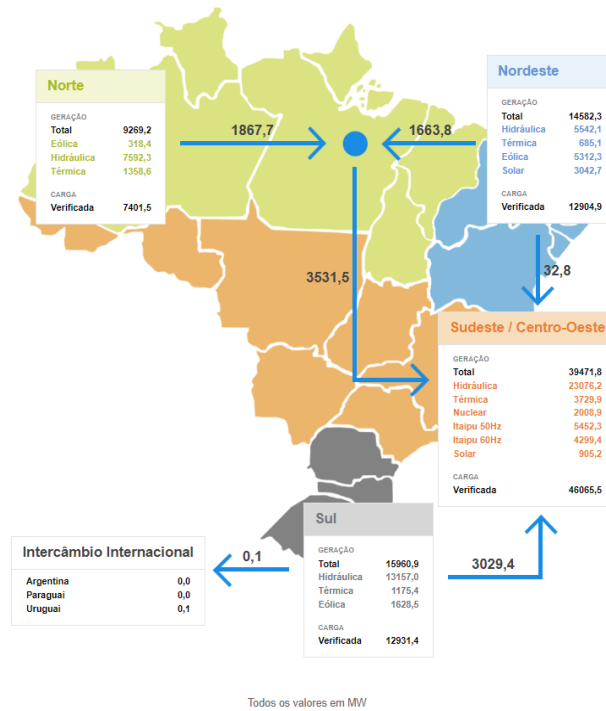
Figura 2 - Evolução da Capacidade Instalada no SIN



Fonte: (ONS, 2022)

Por fim, devido ao vasto território brasileiro, o SIN é subdividido em 4 subsistemas, são eles: Sul, Sudeste/Centro-Oeste, Norte e Nordeste (DE ALMEIDA,2022). Na Figura 3, é apresentado os subsistemas com suas respectivas participações na geração de energia para o país.

Figura 3 - As Subdivisões do SIN



Fonte: (ONS,2022)

## 2.2 Agência Nacional de Energia Elétrica

O setor elétrico apresenta características distintas, visto que é considerado estratégico devido ao seu papel de fornecedor de um bem público, energia elétrica, vital para a manutenção não só econômica, como também do bem-estar da população, no atual estado da sociedade (DE CASTRO; ROSENAL, 2016).

O papel de reguladora do sistema elétrico no Brasil é destinado à Agência Nacional de Energia Elétrica (ANEEL). O contexto de surgimento da autarquia se deu no processo de privatizações das empresas estatais e das concessões de serviços públicos colocadas a cabo primeiramente no Governo Collor (1990-1992) e posteriormente ampliadas no Governo Fernando Henrique Cardoso (1995-2003). Por sua vez, a base teórica dessas medidas é o entendimento de que para superar as dificuldades originadas na década anterior, principalmente após a crise da dívida, fez-se necessário um reajuste na base organizacional do Governo Federal, assim durante toda a década de 1990 ocorreram diversas reformas podendo-se destacar a



administrativa. Nessa, o papel do Estado passou de um ente ativo para se tornar um administrador público de resultados (MANOEL *et al*, 2018). Ademais, devido a essa, o setor elétrico no Brasil passou a ter elementos de um mercado clássico, dentre eles é válido citar: a separação das funções de geração, transmissão, distribuição e comercialização; um operador independente; e um regulador (FERNANDES, 2014).

Por meio da Lei nº 9.427, de janeiro de 1996 foi promulgada a criação da ANEEL, autarquia atrelada diretamente ao Ministério de Minas e Energia, teria as prerrogativas de “regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica, em conformidade com as políticas e diretrizes do governo federal”. Ademais, ficam explicitadas as funções do órgão regulador de energia, dentre elas é possível destacar: I) implementar as políticas e diretrizes do governo federal para a exploração da energia elétrica e o aproveitamento dos potenciais hidráulicos; II) gerir os contratos de concessão ou de permissão de serviços públicos de energia elétrica, de concessão de uso de bem público, bem como fiscalizar, diretamente ou mediante convênios com órgãos estaduais, as concessões, as permissões e a prestação dos serviços de energia elétrica; III) dirimir, no âmbito administrativo, as divergências entre concessionárias, permissionárias, autorizadas, produtores independentes e autoprodutores, bem como entre esses agentes e seus consumidores; IV) zelar pelo cumprimento da legislação de defesa da concorrência, monitorando e acompanhando as práticas de mercado dos agentes do setor de energia elétrica (GOVERNO, 2022).

Na prática, através de instrumentos como fiscalizações periódicas ou imprevistas, revisões das tarifas ou das regulamentações, a ANEEL incentiva as empresas inseridas no meio a realizar projetos e serviços que causem inovação tanto no que se refere aos processos administrativos, quanto operacionais. Com isso, há não só um aumento da qualidade do serviço prestado ao consumidor, como também o desenvolvimento do setor de energia elétrica como um todo (MANOEL *et al*, 2018).

### **2.3. Revisão Da literatura para a modelagem do Setor Elétrico**

Com o objetivo de melhor compreender o atual estado da arte no que diz respeito ao uso de métodos estatísticos no setor elétrico brasileiro, a seguir é exposta uma breve revisão da literatura.

Luz *et al* (2019) utiliza os modelos MAE e MBJ na série de consumo de energia elétrica no Brasil. Ademais, é verificado a capacidade preditiva dos modelos por meio de estatística

de aderências, dentre elas, o RMSE. Dentre os modelos gerados, o MBJ foi aquele que obteve melhor resultado.

Dos Santos *et al* (2022) faz a análise da demanda por energia elétrica no estado do Rio Grande do Sul para os três principais setores consumidores: residencial, comercial e industrial. Para isso, utiliza o modelo vetorial autorregressivo, complementado pelo modelo vetorial de correção de erros. Ademais, as seguintes variáveis foram utilizadas: tarifa de energia elétrica, PIB, preços de eletrodomésticos e preço de matérias e equipamentos elétricos. Também, a capacidade dos modelos gerados foi comparada com o da MBJ. Por fim, foi obtido que a MBJ obteve a melhor capacidade preditiva.

Tidre *et al* (2014) por meio da análise da série temporal do consumo de energia elétrica para a região Nordeste estimou um modelo SARIMA (2, 1, 2)(0, 1, 1)<sub>12</sub>. . Ademais, foi-se encontrado previsões relativamente precisas.

Oliveira *et al* (2021) utiliza o Modelo de Amortecimento Exponencial para gerar previsões de carga diária. Na série observada encontrou-se dois padrões distintos de sazonalidade, mais especificamente, um ciclo sazonal dentro do dia formado por 48 horas e um ciclo sazonal dentro da semana constituído por 336 períodos. Assim, para solucionar essa peculiaridade foi proposto o Modelo Holt-Winters Sazonal Duplo.

Nascimento (2022) realiza um estudo comparativo de desempenho de metodologias preditivas de series temporais para a previsões do preço de energia elétrica. Para isso, foram utilizados os modelos MAE, MBJ e RNA. Depois, realizou-se a comparação de métricas de erro, dentre elas a RMSE, para verificar a avaliação de erro de previsão. O resultado demonstra que o método de RNA é superior aos demais.

Por fim, em Antonioli *et al* (2021) é feita uma revisão sistemática de 15 artigos que utilizara redes neurais artificiais para a previsões do consumo de energia elétrica. Nesse aspecto são discutidas as principais variáveis de entrada, configuração da rede e performance, além de identificar se o conjunto de métodos de RNA são adequados para a previsão de energia elétrica.

### 3. METODOLOGIA E BASE DE DADOS

#### 3.1 Série Temporal X Processo Estocástico

No presente trabalho, serão utilizadas três metodologias na estimação de um modelo preditivo para o consumo mensal total de energia elétrica mensal no Brasil. Todos esses métodos apresentam uma natureza “auto projetiva”, ou seja, a única variável utilizada na estimação será a própria série. O pressuposto dessa metodologia é que, mesmo com o comportamento irregular, é testado a hipótese de que a série pode se autoexplicar. Isso quer dizer que a utilização de um modelo autoprojeto já teria resultados significativos na previsão de valores futuros (ZANINI, 2001). Os métodos utilizados são: MAE (Método de Amortecimento Exponencial), MBJ (Método de Box & Jenkins) e RNA (Rede Neural Artificial). Antes de ser feita a apresentação de cada um deles, porém, é necessário ser exposto a definição de alguns conceitos básicos.

Em primeiro lugar, uma série temporal é um grupo de observações de uma dada variável ordenadas segundo o parâmetro do tempo, e que, geralmente, apresentam um intervalo de tempo equidistante. Considerando que  $Z_t$  representa o valor da variável aleatória  $Z$  no instante  $t$ , representa-se a série temporal por  $Z_1, Z_2, \dots, Z_N$ ; onde  $N$  é o tamanho da série ou o número de observações seriais da variável. No que tange à classificação, são divididas em: discretas, contínuas, determinísticas, estocásticas, multivariadas (discretas ou contínuas) e multidimensionais (SOUZA; CAMARGO,1996). Ademais, como demonstrado por Zanini (2001), nem todo o evento observado no tempo é classificado como uma série temporal, sendo que, para que isso ocorra, as observações devem ter dependência serial, isto é, sejam dependentes no tempo.

Como descrito por Harvey e Peters (1990), uma forma de análise das séries temporais é por meio de decomposição em componentes de nível, tendência, sazonalidade e componente irregular(erro). Em primeiro lugar, caso considerado que não há crescimento ou decréscimo no longo prazo, o componente de nível é o valor ou faixa de valores típicas na qual a variável pode assumir. Em segundo lugar, a tendência é entendida como o comportamento de longo prazo da série temporal, tendo as características de crescimento, decréscimo ou estacionaridade. Em terceiro lugar, a sazonalidade é a repetição de um determinado padrão tendo este um período de tempo definido, por exemplo, mensal, semestral, anual, etc. Por fim, o componente irregular é de natureza aleatória, ou seja, o que não é explicado como nível, tendência ou sazonalidade.

Segundo Zanini (2012), um processo estocástico caracteriza-se por uma sequência no tempo de variáveis aleatórias, ou seja, um modelo que descreve a estrutura de probabilidade de uma sequência de observações. Matematicamente,  $Z = \{Z(t), t \in \mathbf{N}\}$ , tal que  $t \in \mathbf{R}$ ,  $Z(t)$  sendo uma variável aleatória. Caso  $\mathbf{N} \equiv Z = \{1, \dots\}$  o processo é de parâmetro discreto, denotado por  $Z$ . Se  $\mathbf{N} \in \mathbf{R}$ , o processo é de parâmetro contínuo, denotando-se por  $Z(t)$ . Atrelando esses dois conceitos, tem-se à conclusão que uma série temporal é uma parte da trajetória ou uma realização parcial de um processo estocástico. Então, o processo do estudo de uma série temporal é entendido seguindo um processo lógico: de uma determinada realidade, processo estocástico, é retirada uma amostra finita de observações, série temporal, e através da análise dessa amostra busca-se identificar um modelo e inferir um comportamento da realidade.

### 3.2 Competição de modelos

É válido destacar que para estimar-se a equação de previsão, um dos passos do processo se dá na análise da estrutura de correlação dos dados históricos e da representação desta, por exemplo, através do cálculo de fatores como nível, tendência e sazonalidade. Com os parâmetros do modelo estimados, antes de calcular as previsões, faz-se necessário relaxar a projeção dos valores históricos com o objetivo de comparar os valores reais e os valores ajustados pelo modelo. Assim, é por meio dessa comparação que se dá o cálculo do erro de previsão oriundo do modelo ao se projetar os dados históricos. A partir dessa medida, é feito o cálculo para as previsões um passo-à-frente, isto é, um período de tempo à frente. Esse valor é utilizado como um indicador para o desempenho preditivo do modelo para o horizonte futuro, sob a hipótese de que não ocorram mudanças significativas no processo gerador da série histórica (ZANINI, 2012).

Em síntese, por meio da comparação entre os valores reais e os valores ajustados pelo modelo, é feito o cálculo para medir o desempenho do mesmo. Essa medida é utilizada para avaliar o desempenho do modelo estimado dentro da amostra de dados utilizados na modelagem (ZANINI, 2012).

Feitas estas considerações, atenta-se que, no presente trabalho, dentre as diversas métricas disponíveis na literatura, será utilizada a RMSE (*Root Mean Square Error*), cuja fórmula de cálculo é exposta pela equação 1.

$$RMSE = \sqrt{\frac{\sum_{t=1}^N \left( Y(t) - \hat{Y}(t) \right)^2}{N}} \quad (1)$$

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)

Assim, dentre os modelos gerados, aquele que minimiza o RMSE é considerado o com o melhor desempenho preditivo.

### 3.3 Método Amortecimento Exponencial (MAE)

Conforme Zanini (2012), o modelo ingênuo (*Naive*) é o qual utiliza-se para a previsão o último dado, como demonstrado na equação 2.

$$\hat{Z}_T(\tau) = Z_T \quad (2)$$

Onde:

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

$Z_T$ : último dado disponível

$\tau$ : horizonte de previsão

Outra maneira um pouco mais elaborada que a estimação se dá por meio da média ou média móvel dos dados. como demonstrado na equação 3 e 4:

$$\hat{a}(T) = \bar{Z}_T = \frac{1}{T} \sum_{i=1}^T Z_i \quad (3)$$

$$\hat{a}(T) = MM(N) = M_T = \frac{Z_T + Z_{T-1} + Z_{T-N+1}}{N} \quad (4)$$

Onde:

MM(N): média móvel de tamanho N.

Porém, como já relatado anteriormente, a série apresenta alterações por fatores importantes como, por exemplo, nível, sazonalidade e tendência, principalmente se a série em questão tiver uma duração muito elevada ou apresentar alta variância. Com isso, conclui-se que ambos os métodos descritos acima possuem uma deficiência que se dá no fato de que para o cálculo dos parâmetros, todos os dados têm o mesmo peso (ZANINI, 2012).

Uma solução para superar essa deficiência é utilizar o método do “Amortecimento Exponencial”. Considerando uma série que não apresenta nem tendência nem sazonalidade. A equação de previsão do mesmo poderia ser exposta pela equação 5:

$$Z_t = a(T) + \varepsilon_t \quad (5)$$

Onde:

$Z_t$  = valor no período t (t = 1, 2, ..., T);

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

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

O objetivo agora é a otimização do cálculo para o parâmetro “a”, e para isso utiliza-se duas informações importantes. Primeiro, a estimativa de “a” feita no final do período anterior e, em segundo lugar, o último dado disponível ( $Z(T)$ ). Com isso, calcula-se uma estimativa na variação, (T-1), que se dá pelo nível por uma fração do erro de previsão resultante da estimativa para o dado mais recente. Sendo o erro de previsão no último período  $\varepsilon(T) = Z(T) - \hat{a}(T-1)$ , a formulação matemática é demonstrada na equação 6.

$$\hat{a}(T) = \hat{a}(T-1) + \alpha * [ Z(T) - \hat{a}(T-1) ] \quad (6)$$

$$\hat{a}(T) = \alpha * Z(T) + (1 - \alpha) * \hat{a}(T-1) \quad (7)$$

Clareando a notação, considere que  $\hat{a}(T) \equiv S$ . Com isso, a equação é representada:

$$S_T = \alpha * Z_T + (1 - \alpha) * S_{T-1} \quad (8)$$

Onde:

$S_T$  = valor amortecido da série;

$\alpha$  = constante de amortecimento ou hiperparâmetro (número entre 0 e 1).

A equação 8 é a ideia básica do método de amortecimento exponencial para uma série que apresenta apenas o componente de nível. Considerando uma série que tendo também os componentes de tendência e sazonal chega-se na equação 9:

$$Z_t = (a_1(T) + a_2(T) * t) * \rho_t + \varepsilon_t \quad (9)$$

Onde:

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

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

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

$\rho_t$ : fator sazonal referente ao período t;

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

### 3.4 Método de Box & Jenkins (MBJ)

De acordo com Zanini (2012), a Metodologia de Box & Jenkins caracteriza-se por duas ideias fundamentais. São elas: o princípio da parcimônia, isto é, a construção de um modelo, dada uma representação matemática adequada, com o menor número de parâmetros possíveis. E, a elaboração do modelo através de um ciclo iterativo, isto é, a seleção de modelos até que se encontre um modelo cujo os parâmetros sejam considerados satisfatórios. Para isso, é feito um processo que consiste nas seguintes etapas: primeiro, é feita a identificação da estrutura do modelo, depois é realizada a estimação paramétrica, por fim é realizado teste com o objetivo de validar o modelo.

De início, identifica-se a ordem de homogeneidade “d”, ou seja, caso necessário, distinguir o número de vezes que a série original deve ser diferenciada para se tornar uma série

estacionária, isto se dá quando o processo estocástico que gerou a série temporal não apresenta variação ao longo do tempo. Depois, é feita a identificação do modelo, isso é, da sua ordem (identificação de “p” e “q”). Após a identificação da ordem do modelo, se faz necessário obter as estimativas dos parâmetros do mesmo. Para isso utiliza-se a técnica da máxima verossimilhança. Por fim, são feitos os testes de aderência no qual é verificado a adequação final do modelo. Nestes, destacam-se os testes de resíduos, é verificado se o erro não apresenta nenhuma estrutura de correlação e o teste de sobre fixação no qual é gerado modelos de ordem superior ao identificado com o intuito de reforçar a pertinência deste (ZANINI, 2012).

Dado uma série que não estacionária e que apresenta componentes sazonais utiliza-se os modelos “**SARIMA**” que tem como base os processo descrito acima. A equação 10 demonstra a equação geral do modelo “**SARIMA**”.

$$\phi(B)\Phi(B^S)\nabla_S^D\nabla^d Z_t = \theta(B)\Theta(B^S)a_t \quad (10)$$

Onde:

- $\phi(B)$  : operador não sazonal auto-regressivo
- $\phi_i$  : parâmetros auto-regressivo não-sazonais
- $\nabla^d = (1-B)^d$  : operador diferença não sazonal de ordem d
- $\Phi(B^S)$  : operador sazonal auto-regressivo
- $\Phi_i$  : 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
- $\theta_i$  : parâmetros de médias móveis não sazonais
- $\Theta(B^S)$  : operador sazonal de médias móveis
- $\Theta_i$  : parâmetros de médias móveis sazonais




### 3.5 Redes Neurais Artificiais (RNA)

Uma Rede Neural Artificial (RNA), conforme descrita por Ciaburro *et al* (2017), consiste de um modelo estatístico que utiliza de um conjunto de dados para gerar equações não lineares, o que adiciona a esses modelos uma complexidade capaz de resolver uma gama maior de problemas presentes no mundo real. Com isso, uma RNA é entendida como um sistema de processamento massivamente paralelo, constituído por unidades simples com capacidade de armazenar conhecimento e disponibilizá-lo para uso futuro (HAYKIN, 1998).

Os modelos de RNA são inspirados no modo como o cérebro humano funciona. Como apontado por Ciaburro *et al* (2017), o cérebro possui a capacidade de processar uma gigantesca quantidade de informação usando para isso dados gerados pelos sentidos humanos. Nesse aspecto, o processamento de informação é realizado por células denominadas neurônios, que tem seu funcionamento na base na passagem de sinais elétricos pelas mesmas. Na Figura 4 é exposta uma representação visual de um neurônio.

Figura 4 - Neurônio biológico.



Fonte: (CIABURRO *et al* 2017).

Conforme (CIABURRO, *et al* 2017), os componentes principais de um neurônio são:

- Dendritos: a porta de cada entrada do neurônio. Tem a função de captar a informação (input) gerada pelos neurônios antecessores na rede;
- Corpo Celular: é responsável por inserir a informação trazida pelo dendrito e, com isso, decidir qual ação deve realizar;

- Terminal Do Axônio: é responsável por transmitir a informação(output), na forma de impulso elétrico, para o processo de neurônio

Com isso, as RNA's baseiam-se estrutura biológica para seu funcionamento, onde os dados ou inputs são transmitidos para um ou mais neurônios artificiais que computam-na, por meio de funções matemáticas e, dependendo do valor encontrado, transmitem uma informação na forma de uma saída ou output. Com o avanço dessas técnicas, principalmente nos últimos anos, é válido destacar que há inúmeros métodos disponíveis na literatura para utilidades diversas, como por exemplo, há modelos que são empregados para a classificação de grupos presentes nos dados, enquanto outros são aplicados para a previsão de um valor futuro. No entanto, há regras básicas que permeiam todos, podendo-se distinguir as RNA's por três características principais, são essas: (a) o padrão de conexões entre as unidades (*arquitetura* ou *estrutura*), (b) métodos de determinação dos pesos, das conexões (*algoritmo de treinamento* ou *aprendizagem*) e (c) função de ativação (ZANINI *et al* ,2001). A seguir, será discutido esses tópicos com mais detalhes.

O primeiro item necessário para o desenvolvimento de um modelo de RNA é a seleção da base de dados que será utilizada, essas são de diversas formas, por exemplo, sequência de números de uma série temporal, uma matriz de números que formam os pixels de uma imagem, etc. Como destacado por Zanini *et al* (2001) é de extrema importância que ao escolher os exemplos, esses representem de maneira significativa o objeto de estudo desejado. Seja qual for a natureza dos dados, chama-se estes de inputs. Por outro lado, há um conjunto de saídas que será disponibilizado pela rede, denominado output. Segundo Ciaburro *et al* (2017), define-se output como a função da soma dos pesos dos inputs mais o viés, sendo cada neurônio responsável de computar uma operação matemática que consiste em verificar se a soma do total recebida excede o nível desejado, também conhecido como *Threshold*, caso positivo, o neurônio é ativado. Entre os dois, há uma ou mais camadas ocultas, ou *Hidden Layer*, onde as informações são processadas para que depois, sejam fornecidos os outputs.

Agora, o passo seguinte se dá na definição de como ocorre o cálculo matemático na camada oculta para a formação dos outputs. Para isso, vê-se necessário esclarecer os conceitos de Pesos(*Weights*), Viés(*Biases*) e Função de Ativação.

Segundo Hastie *et al* (2009), os pesos são definidos como parâmetros numéricos que demonstram o quão forte cada neurônio afeta os outros. Por exemplo, considerando um

conjunto de inputs  $Y = x_1, x_2, x_3$ , os pesos serão descritos por  $W = w_1, w_2, w_3$ . Com isso, matematicamente a conta feita por cada neurônio é:

$$Y = f(x) = \sum x_i w_i \quad (11)$$

Já o viés, é definido como o intercepto numa equação linear, sendo, a utilidade do viés nas RNA's é de ajustar os outputs com a soma dos pesos dos inputs para cada neurônio (CIABURRO *et al* 2017). É denotado matematicamente a ideia acima descrita na equação 12:

$$output = sum(weights \times inputs) + bias \quad (12)$$

Por fim, é aplicado uma função nos outputs, essa é denominada função de ativação. É conveniente se ressaltar que a parcela de não linearidade dos modelos de RNA ocorre justamente na função de ativação. Ademais, o fator que viabiliza a construção de relações não lineares complexas é justamente a soma destas não linearidades (ZANINI *et al*, 2001) A seguir expõe-se alguns exemplos de funções de ativação.

Primeiramente, pode-se destacar a função linear, essa função é comumente utilizada na camada dos outputs (CIABURRO *et al*, 2017). Nesse caso, o valor dos outputs e dos inputs são coincidentes, variando entre  $-\infty$  e  $+\infty$ . A forma matemática é expressa na equação 13.

$$y = f(x) = x \quad (13)$$

Em segundo lugar, destaca-se a função Sigmoides, uma característica relevante dessa função é forçar com que os valores fiquem restritos ao intervalo de 0 a "a". Além do que, destaca-se que as funções do grupo sigmoides são diferenciáveis e não decrescentes (ZANINI *et al*, 2001). A forma matemática é expressa na equação 14.

$$\varphi(v) = 1/[1 + \exp(-av)] \quad a > 0 \quad (14)$$


Por último, há a Função Tangente Hiperbólica, essa apresenta as mesmas características do que a Função Sigmoides, porém o intervalo de restrição é varia de "-a" e "a". A forma matemática é exposta na equação 15.

$$\varphi(a) = \tanh(a) = (e^a - e^{-a})/(e^a + e^{-a}) \quad a > 0 \quad (15)$$

No contexto das RNA's, utiliza-se o termo arquitetura para descrever como se dá a forma em que a conexão entre os neurônios ocorre. Como no caso das funções de ativação, encontram-se diversos tipos de arquiteturas na literatura, porém o presente trabalho irá restringir-se à arquitetura de “Feedforward Propagation” A seguir, é descrito com mais detalhe a ideia acima exposta.

Como apresentado por Ciaburro *et al* (2017), o processo de “*Feedforward Propagation*” acontece quando o processamento de informação ocorre dos inputs para as camadas ocultas, e por último para os outputs, como é demonstrado na imagem 5.

Figura 5 - O Processo de "Feedforward Propagation".



Fonte: (CIABURRO *et al* 2017).

Nesse sentido, é feito cálculo ( $output = \sum(weights \times inputs) + bias$ ) para cada neurônio presente na rede. Por fim, quando a informação chega na camada de output realiza-se o cálculo do erro, isto é, o valor predito pela rede menos o valor original. Com isso, supondo que  $t$  é o índice que representa o tempo,  $y(t)$  a saída apresentada pelo neurônio, e  $d(t)$  a saída desejada. A formulação matemática do erro para o neurônio  $j$  é descrita na equação 16.

$$e_j(t) = d_j(t) - y_j(t) \quad (16)$$

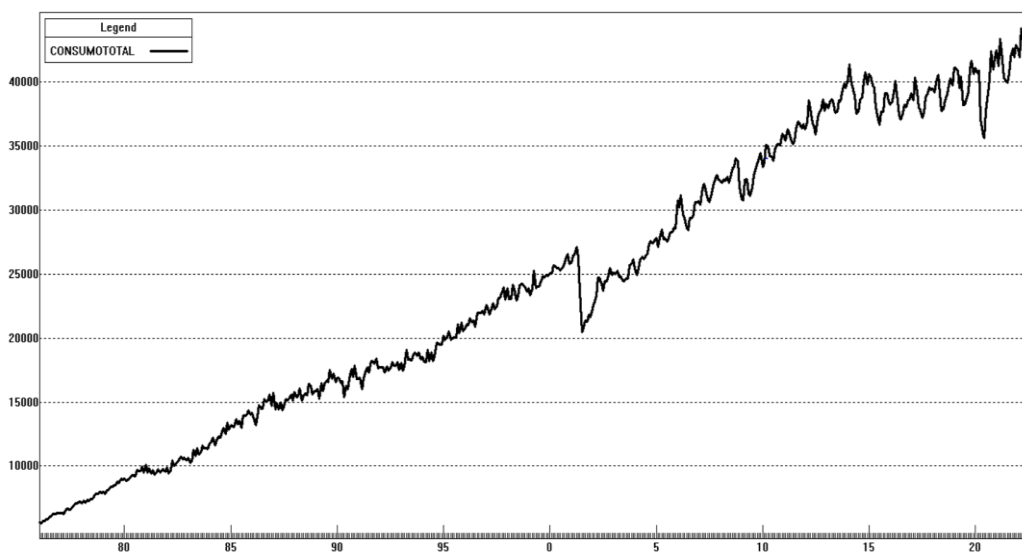
A partir do valor de  $e(t)$  é que se dá as alterações no valor dos pesos e do viés. No contexto das RNA's a repetição contínua do processo descrito anteriormente é denominado 'aprendizado' ou “treinamento”. Como demonstrado por Haykin (1998), entende-se esse processo como a adaptação dos parâmetros de uma rede feita pela apresentação de estímulos fornecidos pelo ambiente. Ademais, segundo Zanini *et al* (2001), a capacidade de aprendizagem é considerada como uma das características marcantes desse tipo de metodologia. Além do que, a definição de aprendizagem implica que certa sequência de eventos se desencadeia, são eles:(a)

ocorre a apresentação de estímulos à rede neural; (b) ocorrência da alteração dos parâmetros da rede; (c) novo padrão de resposta ao ambiente é gerado.

### 3.6 BASE DE DADOS:

Os dados utilizados no presente trabalho monográfico são os do consumo mensal total de energia elétrica no Brasil em GWh. Essa série é disponibilizada no site do IpeaData<sup>4</sup>. A evolução desta variável no tempo é exposta na Figura 6.

Figura 6 - Consumo Mensal Total de Energia Elétrica (GWh) - 1976-2022



Fonte: Elaboração Própria.


Observa-se uma tendência de aumento contínuo na série desde o início, que se dá no ano de 1976. A queda ocorrida no ano de 2001 foi ocasionada pelo racionamento de energia ocorrido naquele ano, ou seja, um fator externo. Outro exemplo similar é notado no final do gráfico, no início de 2020, devido à pandemia do COVID-19 e as consequentes medidas de distanciamento social implementadas para conter a doença. Porém, a princípio, não parece causar efeito duradouro como foi o evento de choque de oferta de 2001. Destaca-se que, caso fosse analisado o consumo de forma desagregada, ou seja, por classes de consumo (comercial, industrial, residencial e outras) é provável que esses eventos tenham impactos diferenciados por setor.

Porém, nota-se que a partir do ano de 2015 a tendência de crescimento dá lugar à estagnação, restando apenas os movimentos causados pela sazonalidade. Essa mudança de comportamento é relevante até porque é comum se utilizar o consumo de energia elétrica como proxy do nível de atividade econômica, ou seja, há evidências que essas duas variáveis são fortemente correlacionadas (MENDES *et al*, 2014).

<sup>4</sup> [www.ipeadata.gov.br](http://www.ipeadata.gov.br)

Visto que o objetivo é estimar, na medida do possível, um modelo mais fidedigno com a realidade e realizar previsões com um baixo erro, nesse trabalho utilizar-se-á a série a partir do ano de 2015 que, a princípio, representa melhor a realidade mais recente da evolução do consumo de energia no Brasil. Na Figura 7 é exposta a variável de consumo de energia elétrica foco desta monografia.

Figura 7 - Consumo Mensal Total de Energia Elétrica (GWh) - 2015-2022



Fonte: Elaboração própria.

#### 4. RESULTADOS

Em relação ao Método de Amortecimento Exponencial (MAE), estimou-se um modelo com componentes de nível e sazonalidade. A equação 17 representa a equação de previsão.

$$Z_t = (42.264) * \rho_t \quad (17)$$

Onde os valores dos fatores sazonais ( $\rho_t$ ) são expostos na Tabela 1.

Tabela 1 - Fatores Sazonais

Mês	$\rho_t$
Janeiro	1,01634
Fevereiro	1,00449
Março	1,03596
Abril	1,00387
Maió	0,98080
Junho	0,96272
Julho	0,97137
Agosto	0,98710
Setembro	0,99815
Outubro	1,01984
Novembro	1,00964
Dezembro	1,01222

Fonte: Elaboração própria.



Para fins de exemplo, atenta-se que o cálculo da previsão do mês de janeiro de 2023 é exposto na equação 18.


$$Z = (42.264) * (1,01634) \quad (18)$$

$$Z = 42.954,30 \text{ GW/h}$$

Isto significa que o mês de janeiro implica num crescimento de cerca de 1,6% no nível mensal do consumo de energia elétrica no Brasil. De modo similar, vê-se, através da análise da tabela 01, que há incremento de consumo nos meses de outubro a abril. Por outro lado, observa-se queda os meses de maio a setembro.

Na Figura 8, expõe-se a previsão realizada pelo modelo, na qual, a linha vermelha representa os valores esperados/previstos, já as linhas azuis representam os valores previstos levando em consideração um intervalo de confiança de 95%.

Figura 8 - Previsão do Consumo de Energia Elétrica no Brasil - MAE




Fonte: Elaboração própria.

Em relação a Metodologia Box & Jenkins (MBJ), estimou-se um modelo ARIMA (0,1,1)\*(1,0,0). A equação 19 representa o modelo estimado.

$$(1-0,36661\beta^{12})(1-\beta)Z_t = (1-0,1092)a_t \quad (19)$$

Na Figura 9 expõe-se a previsão realizada pelo modelo, na qual, a linha vermelha representa os valores esperados/previstos, já as linhas azuis representam os valores previstos levando em consideração um intervalo de confiança de 95%.

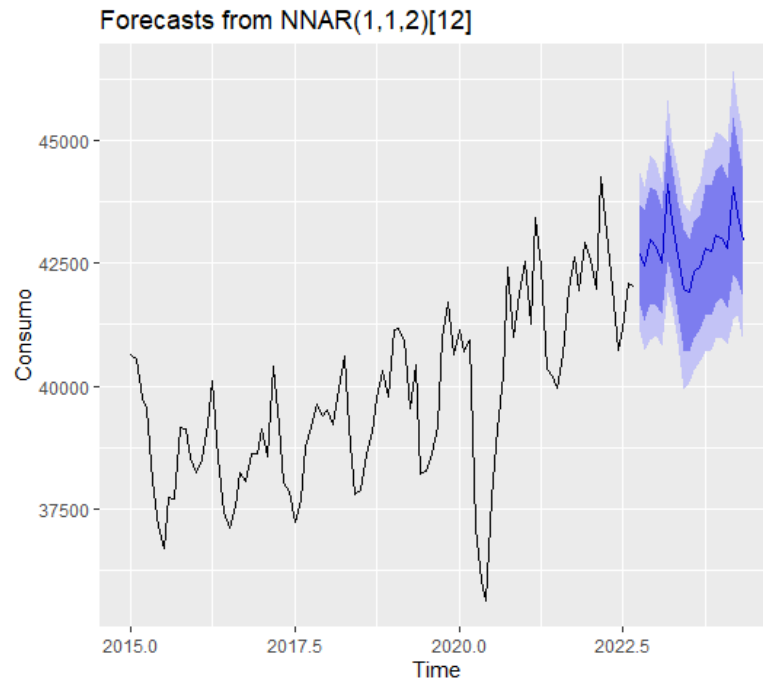
Figura 9 - Previsão do Consumo de Energia Elétrica no Brasil - MBJ



Fonte: Elaboração própria.

O modelo de RNA estimado é do tipo *Feedforward* com uma camada escondida e 2 neurônios. Para isso, geraram-se 20 redes iniciadas com diferentes pesos, e para fazer a previsão, é considerado a média dessas. Na Figura 10 é exposto o gráfico da previsão no qual a linha azul escura representa os valores esperados/previstos, enquanto a parte hachurada em azul claro representa o intervalo de confiança com um nível de confiança de 80%. Já a parte em azul escuro representa o intervalo de confiança com nível de confiança de 95%. É válido destacar que, ao contrário dos métodos antes expostos, no método de RNA's não é possível derivar uma equação matemática de previsão.

Figura 10 - Previsão do Consumo de Energia Elétrica no Brasil - RNA



Fonte: Elaboração própria.

Nas Tabelas de 2 a 4, são expostos os valores das previsões com o intervalo de confiança de 95% para os três métodos.

Tabela 2 - Previsão do Consumo de Energia Elétrica no Brasil (GWh) – MAE

	Limite		
	inferior	Valor esperado	Limite superior
10/2022	41.296	43.171	44.908
11/2022	40.648	42.671	44.698
12/2022	40.578	42.786	45.010
01/2023	40.527	42.957	45.384
02/2023	39.868	42.454	45.045
03/2023	40.993	43.782	46.570
04/2023	39.511	42.428	45.345
05/2023	38.413	41.452	44.492

06/2023	37.533	40.687	43.843
07/2023	37.766	41.054	44.344
08/2023	38.295	41.719	45.144
09/2023	38.633	42.189	45.734
10/2023	39.411	43.101	46.794
11/2023	38.869	42.671	46.471
12/2023	38.861	42.782	46.693

Fonte: Elaboração Própria.

Tabela 3 - Previsão do Consumo Total de Energia Elétrica (GWh) - MBI

	Limite Inferior	Valor esperado	Limite superior
10/2022	40.697	42.481	44.261
11/2022	39.701	42.092	44.484
12/2022	39.775	42.661	45.537
01/2023	39.169	42.459	45.746
02/2023	38.462	42.111	45.759
03/2023	39.426	43.406	47.385
04/2023	38.484	42.770	47.053
05/2023	37.556	42.129	46.700
06/2023	36.534	41.415	46.252
07/2023	36.554	41.669	46.768
08/2023	36.844	42.189	47.519
09/2023	36.581	42.151	47.723
10/2023	36.258	42.404	48.55.
11/2023	35.555	42.18.	48.819
12/2023	35.421	42.505	49.583

Fonte: Elaboração Própria.

Tabela 4 - Previsão do Consumo de Energia Elétrica no Brasil (GWh) - RNA

	Limite inferior	Valor Esperado	Limite Superior
10/2022	40.868	42.569	44.329
11/2022	40.571	42.422	44.165
12/2022	40.751	42.892	44.739
01/2023	40.899	42.826	44.762
02/2023	40.644	42.522	44.344
03/2023	41.728.	44.071	45.647
04/2023	41.509	43.465	45.253
05/2023	40.856	42.727	44.506
06/2023	40.223	42.062	43.849
07/2023	40.021	41.947	43.817
08/2023	40.120	42.262	44.046
09/2023	40.394	42.359	44.189
10/2023	40.519	42.651	44.888
11/2023	40.417	42.670	44.829
12/2023	40.409	42.941	45.425

Fonte: Elaboração Própria.

Na Tabela 5 os valores mensais foram consolidados anualmente, podendo-se ver a variação percentual anual do consumo de energia elétrica total no Brasil. Nessa, nota-se que a série apresenta um comportamento estacionário, ou seja, não houve mudanças significativas no componente de tendência. A única variação expressiva deu-se entre os anos de 2020 e 2021 o que pode ser explicado pelos efeitos das medidas de isolamento durante o primórdio da Pandemia de COVID-19.

Tabela 5 - Consumo Total de Energia Elétrica no Brasil (GWh) e Variação %

Ano	Consumo	Variação
2015	464.600	
2016	460.156	-1,0%
2017	465.039	1,1%
2018	471.643	1,4%
2019	473.944	0,5%
2020	432.800	-8,7%
2021	500.209	15,6%
2022 MAE	508.528	1,7%
2022 MBJ	507.209	1,4%
2022 RNA	507.546	1,5%
2023 MAE	507.277	-0,2%
2023 MBJ	507.386	0,0%
2023 RNA	506.888	-0,1%

Fonte: Elaboração Própria.

Na Tabela 6 expõem-se os valores encontrados do RMSE de cada modelo. Assim, por minimizar o valor do RMSE, é observado que as às RNA apresentam-se como o modelo com melhor desempenho preditivo.

Tabela 6 - RMSE (*Root Mean Square Error*)

Modelo	RMSE
MAE	863,8
MBJ	906,0
RNA	851,9

Fonte: Elaboração Própria.

Por fim, na Tabela 7 expõem-se os valores das previsões da RNA, que foi o método vencedor, para os anos de 2022 e 2023 comparados à previsão feita pela Empresa De Pesquisa Energética (EPE)<sup>5</sup>. Nesse, é observado que, para o ano de 2023, a previsão da RNA é semelhante ao da EPE. No entanto, em relação ao ano de 2023, a EPE considera aumento do consumo, enquanto a previsão da RNA indica um cenário de estabilidade. Importante ressaltar que, obviamente, os métodos utilizados são diferentes. A RNA é um método não-linear, mas os dados de consumo foram tratados de forma autoprojativa. Já a previsão feita pela EPE leva em consideração outros fatores que podem afetar o consumo de energia.

Tabela 7 - Comparação da Previsão Anual RNA X EPE (GWh)

	2022	2023
RNA	507.546	506.888
EPE	510.392	528.814

Fonte: Elaboração Própria.

<sup>5</sup> [www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/revisoes-quadrimestrais-da-carga](http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/revisoes-quadrimestrais-da-carga)

## 5. CONCLUSÃO

O setor de energia elétrica no Brasil apresenta características distintas no que diz respeito à forma pela qual a matriz energética é composta. Por um lado, grande parte da geração de energia se dá por fontes limpas, principalmente a geração por meio de hidrelétricas, por outro, o grande custo socioambiental na construção e manutenção desse tipo de geração de energia, atrelado a um regime de chuvas irregular dos últimos anos, é motivo de preocupações dos formuladores de política pública. No entanto, no século XXI, é válido destacar que a participação de outros tipos de fonte renováveis, especialmente para a solar eólica, vem tendo um aumento significativo.

As mudanças ocorridas na década de 1990 culminaram, entre outras coisas, na privatização de empresas estatais e de concessões de serviços públicos. Com isso, com o intuito de “regular e fiscalizar a produção, distribuição e comercialização de energia elétrica”, surge a ANEEL, autarquia que está atrelada diretamente ao Ministério de Minas e Energia. Na prática, a ANEEL, por meio de suas prerrogativas legais, não só dá cabo de fiscalizar os diversos entes do mercado, como também incentiva as empresas inseridas no meio a relaxar projetos que causam inovação do setor.

Esse trabalho teve o objetivo principal de estudar e aplicar métodos de análise aplicados a séries de tempo ao consumo mensal total de energia elétrica no Brasil. Fez-se a aplicação de dois métodos autoprojetivos lineares, mais especificamente o Método de Amortecimento Exponencial (MAE) e o Método de Box & Jenkins (MBJ). Fez-se ainda a aplicação de um Rede Neural Artificial (RNA), que é um método não-linear. Foram trabalhados os dados mensais de consumo no período de janeiro de 2015 a setembro de 2022, gerando-se as previsões para o período de 2022 a 2023.

No que diz respeito aos modelos, em todos encontrou-se valores semelhantes nas previsões feitas. No entanto, por meio da análise de uma medida de desempenho, mais especificamente da métrica RMSE, conclui-se que o método RNA é aquele com o melhor desempenho preditivo. Ademais, por meio da análise da variação percentual do consumo total anual entre 2015 e 2023, conclui-se que o consumo total de energia elétrica no Brasil tem caráter estacionário, ou seja, não ocorrem mudanças significativas no componente de tendência.

Ressalta-se que a utilização de métodos estatísticos de previsão fornece não apenas um valor pontual, a previsão, mas um intervalo de confiança que possui determinada probabilidade de conter o valor esperado da previsão. Desta forma, poder-



se-ia, por exemplo, utilizar os limites desse intervalo como possíveis cenários a serem trabalhados. Por exemplo, o limite inferior poderia ser visto como um cenário “pessimista”, já o limite superior como um cenário “otimista”. A previsão poderia ser vista como um cenário “esperado”.

Como sugestão de trabalhos futuros, propõem-se, por exemplo, a modelagem de eventos tanto no MAE quanto no MBJ. A análise para captar os efeitos da pandemia, por exemplo, poderia melhorar a estimação paramétricas com prováveis impactos positivos no desempenho preditivo. No que diz respeito aos modelos RNA, outras arquiteturas de rede neurais artificiais podem ser empregadas, como, por exemplo, as Redes Neurais Recorrentes, que já apresentam um histórico na literatura para os modelos preditivos de séries temporais.

Por fim, como os modelos trabalhados possuem características autoprojativas, ou seja, utilizam apenas a própria variável em estudo para gerar a previsão, vê-se oportuna a modelagem considerando com outras variáveis que possam impactar o consumo de energia elétrica. Esta abordagem poderia ser feita tanto utilizando modelos lineares, como, por exemplo, os Modelos de Regressão Dinâmica, como também os modelos não-lineares como as RNA's.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ANTONIOLLI, Eduarda *et al.* Revisão Sistemática: Aplicações de Redes Neurais Para Previsão Do Consumo De Energia Elétrica. **Revista De Engenharia E Tecnologia**, v. 13, n. 2, 2021.
- BOX, G. E. P., JENKINS, G. M.. **Time Series Analysis, Forecasting and Control**, San Francisco, Holden-Day, 1994.
- CUNHA, Eduardo Argou Aires *et al.* Aspectos históricos da energia eólica no Brasil e no mundo. **Revista Brasileira de Energias Renováveis**, v. 8, n. 4, 2019.
- CIABURRO, Giuseppe *et al.* **Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles**. Packt Publishing Ltd, 2017
- DE ALMEIDA, Rodrigo Nascimento *et al.* Estudo de métodos de previsão de séries temporais aplicados ao preço da energia elétrica no mercado de curto prazo brasileiro. 2022.
- DE CASTRO, Nivalde; ROSENTAL, Rubens. O estado e o setor elétrico brasileiro. **Jornal dos Economistas**.(01/09/2016), 2016.
- DOS SANTOS, Gérson Nunes *et al.* Avaliação da capacidade preditiva de modelos ARIMA e VAR-VEC: o caso da demanda por energia elétrica no Rio Grande do Sul. **Exacta**, v. 20, n. 2, p. 307-335, 2022
- FERNANDES, Eduardo Rossi. As sanções administrativas aplicadas pela Agência Nacional de Energia Elétrica–ANEEL: um estudo sobre a regulamentação e as práticas da agência. 2014.
- Governo,2022. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/leis/19427cons.htm](http://www.planalto.gov.br/ccivil_03/leis/19427cons.htm)>.Acesso em: 28 de outubro. 2022.
- HARVEY, Andrew C.; PETERS, Simon. Estimation procedures for structural time series models. **Journal of forecasting**, v. 9, n. 2, p. 89-108, 1990.
- HASTIE, Trevor *et al.* **The elements of statistical learning: data mining, inference, and prediction**. New York: springer, 2009
- KUBAT, Miroslav. Neural networks: a comprehensive foundation by Simon Haykin, Macmillan, 1994, ISBN 0-02-352781-7. **The Knowledge Engineering Review**, v. 13, n. 4, p. 409-412, 1999.
- Luz, Lucas Primo. Avaliação da capacidade preditiva dos modelos das classes ARIMA e de Amortecimento Exponencial sob diferentes aspectos da abordagem SSA na modelagem e previsão de consumo de energia. 2019.
- Manoel, Caio Augusto Silva *et al.* A importância da ANEEL na prestação dos serviços de energia elétrica no Brasil. **Research, Society and Development**, v. 7, n. 7, p. e377276-e377276, 2018.

MARTINS, Fernando Ramos et al. Atlas brasileiro de energia solar 2. 2017.

Ministério Da Economia, 2022. Disponível: <<http://mdic.gov.br/index.php/comercio-exterior/regimes-de-origem/9-assuntos/categ-comercio-exterior/599-energia>>. Acesso em: 28 de outubro. 2022.

MENDES, Carlos Augusto Nogueira et al. Consumo de energia e crescimento económico: uma relação em estudo com foco nos países componentes do BRICS. 2014.

MONTGOMERY, D.C., JOHNSON, L.A.. **Forecasting and Time Series Analysis**, New York, McGraw-Hill Book Co., 1990.

NASCIMENTO, Rodrigo Almeida. Estudo de métodos de previsão de séries temporais aplicados ao preço da energia elétrica no mercado de curto prazo brasileiro. 2022.

ONS. **O que é SIN**, 2022. Disponível em: <<http://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>>. Acesso em: 26 de outubro. 2022.

Oliveira, Daiane *et al.* Previsão da curva horária do Sistema Interligado Nacional(SIN) utilizando Métodos de Suavização Exponencial. 2021.

SOUZA, Reinaldo Castro; CAMARGO, Maria Emília. Análise e previsão de séries temporais: os modelos ARIMA. **Ijuí: Sedigraf**, 1996.

TIDRE, Pablo Vinicius *et al.* Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. **Matemática e Estatística em Foco**, v. 1, n. 1, p. 57-66, 2013

ZANINI, Alexandre *et al.* Um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no Brasil. In: **Paper presented at: Proceedings of the V Brazilian Conference on Neural Networks**. 2001.

ZANINI, Alexandre. Previsão de séries temporais. Material Didático. 2012.