



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**CÉSAR LÉDIO DE ALENCAR FILHO**

**PREVISÃO DE CARGA PARA CONSUMIDORES DE BAIXA RENDA NO ESTADO  
DO CEARÁ**

**FORTALEZA**

**2023**

CÉSAR LÉDIO DE ALENCAR FILHO

PREVISÃO DE CARGA PARA CONSUMIDORES DE BAIXA RENDA DO ESTADO DO  
CEARÁ

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Orientador: Prof. Dr. Ricardo Silva The Pontes.  
Coorientador: Prof. Dr. Cássio Tersandro de Castro Andrade.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

A353p Alencar Filho, César Lédio de.  
Previsão de carga para consumidores de baixa renda no Estado do Ceará / César Lédio de Alencar Filho. – 2023.  
68 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2023.  
Orientação: Prof. Dr. Ricardo Silva The Pontes.  
Coorientação: Prof. Dr. Cássio Tersandro de Castro Andrade.

1. Suavização exponencial. 2. séries temporais. 3. consumidor baixa renda. 4. previsão de carga. I. Título.  
CDD 621.3

---

CÉSAR LÉDIO DE ALENCAR FILHO

PREVISÃO DE CARGA PARA CONSUMIDORES DE BAIXA RENDA DO ESTADO DO  
CEARÁ

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Aprovada em: 28/09/2023.

BANCA EXAMINADORA

---

Prof. Dr. Ricardo Silva The Pontes (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Paulo Cesar Marques de Carvalho  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Cássio Tersandro de Castro Andrade (Coorientador)  
Membro externo ao PPGEE - UFC

A Jesus, meu Senhor e Salvador.

À minha família.

Aos meus professores e amigos que  
contribuíram para a conclusão deste trabalho.

## AGRADECIMENTOS

À Universidade Federal do Ceará, pelo apoio por meio de toda a infraestrutura do *campus* do Centro de Tecnologia para o desenvolvimento das atividades.

Ao Prof. Dr. Ricardo Silva The Pontes, pela excelente orientação e pelo incentivo ao desenvolvimento das atividades.

Ao Prof. Dr. Cássio Tersandro de Castro Andrade, pela excelente coorientação e pelo incentivo ao desenvolvimento das atividades.

Ao Prof. Dr. Paulo César Marques de Carvalho, pela participação na banca examinadora e pelas valiosas colaborações e sugestões.

À minha família, por todo o apoio e incentivo durante todo o mestrado.

À minha namorada, Samilly, por sempre me apoiar a concluir o mestrado.

Ao meu tio, Henrique, que faleceu durante esse período que estava no mestrado, mas que sempre foi um incentivador nos meus estudos.

Aos professores participantes da banca examinadora, pelo tempo, pelas valiosas colaborações e sugestões.

Aos colegas da turma de mestrado, pelas reflexões, críticas e sugestões recebidas.

“Porque a nossa leve e momentânea tribulação produz para nós eterno peso de glória, acima de toda comparação.” (2 Coríntios, 4:17)

## RESUMO

O desenvolvimento de modelos preditivos de demanda de energia elétrica é componente fundamental na operação do setor elétrico, sendo bastante útil no planejamento e operação de um sistema de eletrificação. As concessionárias de eletricidade precisam prever, da melhor forma possível, a demanda de suas unidades consumidoras, de forma que nos leilões no Ambiente de Contratação Regulada (ACR), estas possam evitar sub ou sobre contratações dentro de sua área de concessão. Diante desse contexto, o objetivo dessa dissertação é testar modelos de previsão de demanda de energia elétrica dos consumidores residenciais na subclasse baixa renda, no Estado do Ceará, utilizando como dados para treinamento dos modelos, os referentes aos anos de 2012 a 2020 e o ano de 2021 para validação dos mesmos. Para tanto, esta pesquisa utiliza três modelos preditivos, no intuito de estimar a demanda de energia elétrica dos consumidores residenciais da subclasse baixa renda. Os modelos são o da Suavização Exponencial; ARIMA (*Auto-Regressive Integrated Moving Average*) e SARIMAX (*Seasonal Auto-Regressive Integrated Moving Average with e Xogenous factors*), com a utilização do salário-mínimo e da tarifa como variáveis exógenas. E o erro percentual absoluto médio MAPE (*Mean Absolute Percentage Error*) como métrica de avaliação dos modelos. Os bancos de dados analisados são da Empresa de Pesquisa Energética (EPE) e ferramentas de programação em linguagem Python, utilizadas para simulação dos modelos. A partir disso, os resultados indicam que os Erros Percentuais Absolutos Médios dos três modelos preditivos utilizados são: 2,91% para a Suavização Exponencial, 3,40% para o ARIMA, 2,99% para o SARIMAX, quando a variável exógena é o salário-mínimo e 2,58% para o SARIMAX, quando a variável exógena utilizada é a tarifa. Com a observação dos padrões, mostra-se erros com boa precisão na previsão da demanda.

**Palavras-chave:** suavização exponencial; séries temporais; consumidor baixa renda; previsão de carga.



## ABSTRACT

The development of predictive models of electrical energy demand is a fundamental component in the operation of the electrical sector, being very useful in the planning and operation of an electrification system. Electricity concessionaires need to predict, as best as possible, the demand of their consumer units, so that in auctions in the Regulated Contracting Environment (ACR), they can avoid under or over contracting within their concession area. Given this context, the objective of this dissertation is to test models for forecasting the electrical energy demand of residential consumers in the low-income subclass, in the State of Ceará, using as data for training the models, those referring to the years 2012 to 2020 and the year 2021 for their validation. To this end, this research uses three predictive models, in order to estimate the electricity demand of residential consumers in the low-income subclass. The models are Exponential Smoothing: ARIMA (Auto-Regressive Integrated Moving Average) and SARIMAX (Seasonal Auto-Regressive Integrated Moving Average with and Xogenous factors), using the minimum wage and tariff as exogenous variables. And the mean absolute percentage error MAPE (Mean Absolute Percentage Error) as a metric for evaluating the models. The databases analyzed are from the Energy Research Company (EPE) and programming tools in Python language, used to simulate the models. From this, the results indicate that the Average Absolute Percentage Errors of the three predictive models used are: 2.91% for Exponential Smoothing, 3.40% for ARIMA, 2.99% for SARIMAX, when the exogenous variable is the minimum wage and 2.58% for SARIMAX, when the exogenous variable used is the tariff. By observing patterns, errors can be shown with good accuracy in forecasting demand.

**Keywords:** exponential smoothing; time series; low income consumer; load forecast.

## LISTA DE FIGURAS

Figura 1 – Exemplos de conjuntos de dados com diferentes níveis de correlação .....	44
---	----

## LISTA DE GRÁFICOS

Gráfico 1	– Curva de carga no dia do jogo do Brasil pela Copa do Mundo 2018 ...	29
Gráfico 2	– Curvas de carga por classe de consumo no Estado do Ceará .....	30
Gráfico 3	– Consumo de energia elétrica na classe residencial no Estado do Ceará	33
Gráfico 4	– Decomposição da série temporal do consumo de energia elétrica na classe residencial no Ceará .....	34
Gráfico 5	– Gráfico da função de autocorrelação da série temporal do consumo de energia elétrica na classe residencial, por mês, no Estado do Ceará, entre os anos de 2004 e 2021 .....	35
Gráfico 6	– Consumo de energia elétrica do consumidor baixa renda no Ceará 2012 e 2021 .....	47
Gráfico 7	– Decomposição da série temporal do consumo de energia elétrica do consumidor baixa renda no Ceará 2012-2021 .....	48
Gráfico 8	– Função de autocorrelação da série temporal do consumo de energia elétrica do consumidor baixa renda no Ceará 2012-2021 .....	49
Gráfico 9	– Matriz de correlação entre as variáveis analisadas .....	50
Gráfico 10	– Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo de Suavização Exponencial .....	51
Gráfico 11	– Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo ARIMA .....	52
Gráfico 12	– Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo SARIMAX com variável exógena salário mínimo .....	54
Gráfico 13	– Comparação dos valores reais de demanda de energia elétrica com os valores previsto no modelo SARIMAX com variável exógena tarifa ....	55

## LISTA DE TABELAS

Tabela 1	– Descontos Consumidores Baixa Renda e Baixa Renda-BPC .....	21
Tabela 2	– Descontos Consumidores Baixa Renda Quilombolas e Indígenas .....	21
Tabela 3	– Percentual do consumo de energia elétrica por classe de consumidores ...	26
Tabela 4	– Séries temporais de Consumo, Consumidores, Consumo Médio, Tarifa e Salário Mínimo no Estado do Ceará entre os anos de 2012 e 2021 .....	46
Tabela 5	– Erro absoluto percentual médio (MAPE) no modelo de suavização exponencial .....	51
Tabela 6	– Erro absoluto percentual médio (MAPE) no modelo ARIMA .....	53
Tabela 7	– Erro absoluto percentual médio (MAPE) no modelo SARIMAX com variável exógena salário mínimo .....	55
Tabela 8	– Erro absoluto percentual médio (MAPE) no modelo SARIMAX com variável exógena tarifa .....	56

## LISTA DE ABREVIATURAS E SIGLAS

ABRACEEL	Associação Brasileira dos Comercializadores de Energia
ACL	Ambiente de Contratação Livre
ADF	<i>Augmented Dickey-Fuller</i>
AIC	<i>Akaike's Information Criterion</i>
ANEEL	Agência Nacional de Energia Elétrica
ARIMA	<i>Auto-Regressive Integrated Moving Average</i>
ARMA	<i>Auto-Regressive Moving Average</i>
BIC	<i>Bayesian Information Criterion</i>
BPC	Benefício de Prestação Continuada da Assistência Social
CADÚNICO	Cadastro Único para Programas Sociais do Governo Federal
CCEE	Câmara de Comercialização de Energia Elétrica
CCER	Contrato de Compra de Energia Regulada
CDE	Conta de Desenvolvimento Energético
CNAE	Classificação Nacional de Atividades Econômicas
CUSD	Contrato de Uso do Sistema de Distribuição
EPE	Empresa de Pesquisa Energética
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
IPEA	Instituto de Pesquisa Econômica Aplicada
KPSS	<i>Kwiatkowski-Phillips-Schmidt-Shin</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MIGDI	Microsistema Isolado de Geração e Distribuição de Energia Elétrica
MMV	Método da Máxima Verossimilhança
ONS	Operador Nacional do Sistema
PDE	Plano Decenal de Expansão de Energia
PRODIST	Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
PIB	Produto Interno Bruto
REN	Resolução Normativa

SARIMA	<i>Seasonal Auto-Regressive Integrated Moving Average</i>
SARIMAX	<i>Seasonal Auto-Regressive Integrated Moving Average with eXogenous factors</i>
SEHW	Suavização Exponencial de Holt-Winters
SEH	Suavização Exponencial de Holt
SES	Suavização Exponencial Simples
SIGFI	Sistema Individual de Geração de Energia Elétrica com Fonte Intermitente
SIN	Sistema Interligado Nacional
TSEE	Tarifa Social de Energia Elétrica
TUSD	Tarifa de Uso do Sistema de Distribuição

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	15
<b>1.1</b>	<b>Motivação</b> .....	16
<b>1.2</b>	<b>Objetivos</b> .....	17
<i>1.2.1</i>	<i>Objetivos gerais</i> .....	17
<i>1.2.2</i>	<i>Objetivos específicos</i> .....	17
<b>1.3</b>	<b>Organização do trabalho</b> .....	17
<b>2</b>	<b>CARACTERIZAÇÃO DA CARGA</b> .....	19
<b>2.1</b>	<b>Classificação dos consumidores</b> .....	20
<i>2.1.1</i>	<i>Residencial</i> .....	20
<i>2.1.2</i>	<i>Industrial</i> .....	21
<i>2.1.3</i>	<i>Comércio, serviço e outras atividades</i> .....	22
<i>2.1.4</i>	<i>Rural</i> .....	23
<i>2.1.5</i>	<i>Poder público</i> .....	24
<i>2.1.6</i>	<i>Iluminação pública</i> .....	24
<i>2.1.7</i>	<i>Serviço público</i> .....	25
<i>2.1.8</i>	<i>Consumo próprio</i> .....	25
<b>2.2</b>	<b>Grupo de consumidores por nível de tensão</b> .....	26
<b>2.3</b>	<b>Consumidores por tipo de mercado</b> .....	27
<b>2.4</b>	<b>Características de curvas de carga</b> .....	28
<b>3</b>	<b>MODELOS DE PREVISÃO DE CARGA</b> .....	31
<b>3.1</b>	<b>Séries Temporais</b> .....	32
<b>3.2</b>	<b>Modelos preditivos</b> .....	36
<i>3.2.1</i>	<i>Suavização exponencial</i> .....	36
<i>3.2.2</i>	<i>ARIMA</i> .....	38
<i>3.2.3</i>	<i>SARIMAX</i> .....	42
<b>4</b>	<b>ESTUDO DE CASO</b> .....	45
<b>4.1</b>	<b>Séries temporais utilizadas</b> .....	45
<b>4.2</b>	<b>Modelagens preditivas</b> .....	50
<i>4.2.1</i>	<i>Suavização exponencial</i> .....	50
<i>4.2.2</i>	<i>ARIMA</i> .....	52
<i>4.2.3</i>	<i>SARIMAX</i> .....	53

<b>5</b>	<b>CONCLUSÃO .....</b>	<b>57</b>
<b>5.1</b>	<b>Trabalhos Futuros .....</b>	<b>57</b>
	<b>REFERÊNCIAS .....</b>	<b>59</b>
	<b>ANEXO .....</b>	<b>62</b>
	<b>ANEXO - CÓDIGO EM PYTHON .....</b>	<b>63</b>



## 1 INTRODUÇÃO

O planejamento é uma ferramenta essencial em todas as áreas profissionais. Através dele, há maior confiabilidade de investimentos e possibilidade de se antecipar a certos problemas que podem ocorrer, podendo evitá-los, dentre outras vantagens. No setor elétrico não é diferente; existe uma série de análises e estudos feitos baseados em medições que auxiliam nos planejamentos há curto, médio e longo prazo.

No Brasil, esses estudos são realizados pela Empresa de Pesquisa Energética (EPE), a qual tem a responsabilidade de subsidiar as diretrizes da política energética elaborada pelo Governo. Quando feitos em conjunto, e de maneira integrada, esses estudos e pesquisas dão um direcionamento ao setor energético em relação à tomada de decisão e ao monitoramento das autoridades governamentais, como, por exemplo, a licitação de linhas de transmissão ou a situação dos reservatórios das usinas hidrelétricas, essa última informação obtida de estudos em conjunto com o Operador Nacional do Sistema (ONS), (doravante EPE, 2023).

Segundo a EPE, o planejamento de curto e médio prazo é consolidado pelo Plano Decenal de Expansão de Energia (PDE), o qual mostra uma perspectiva da expansão do setor energético por parte do Governo nos próximos 10 anos. Com esse planejamento de curto e médio prazo é possível indicar: a expansão de energia elétrica, mostrar custos de políticas públicas voltadas ao setor elétrico, além das licitações de linhas de transmissão. Já os estudos a longo prazo são definidos pela EPE:

Como a base para a formulação de políticas públicas que têm rebatimento na estratégia nacional para expansão da oferta de energia com vistas ao atendimento da demanda, observados os objetivos básicos de segurança energética, universalização do acesso da população aos serviços energéticos, geração de emprego e renda e redução das desigualdades regionais, sustentabilidade ambiental e modicidade de preços e tarifas. Nesse contexto, o planejamento de longo prazo do setor energético é instrumento fundamental para o país, na medida em que avalia tendências na produção e no uso da energia e baliza as estratégias alternativas para expansão da oferta de energia nas próximas décadas e é instrumento fundamental para a explicitação de custos e benefícios de medidas e políticas públicas (EPE, 2023).

Esse contexto, certamente, aguça o interesse de diversos estudiosos, dentre os quais nós incluímos e destacamos como necessário, para a realização deste estudo, saber como se comporta cada classe de consumidor, sendo que essas são definidas conforme a Resolução Normativa ANEEL n.º 414/2010, que foi substituída pela Resolução Normativa ANEEL n.º 1000/2021, dividindo-se em: Residencial, Industrial, Comercial, Rural, Poder Público, Serviços Públicos e Consumo Próprio (ANEEL, 2021).

A partir de uma análise detalhada dos tipos de consumidores e de um planejamento adequado se obtém dados para se investir em determinadas fontes de energia, como, por exemplo, a Geração Distribuída Eólica e Fotovoltaica. Além disso, o plano energético é componente fundamental na elaboração de políticas públicas, pois, a partir da ação adotada pelo país serão destinados os esforços e recursos voltados a resolver esses problemas da população; no caso do setor elétrico, uma energia mais barata, acessível e de qualidade ao consumidor. Dessa forma, se há uma energia mais barata para consumidores residenciais onde a renda familiar é baixa, há mais espaço para que os recursos dessa família sejam realocados em outras coisas, como alimentação, limpeza, dentre outras necessidades.

Isso ocorre com o consumidor residencial da subclasse baixa renda, que são beneficiados com a Tarifa Social de Energia Elétrica (TSEE), a qual concede à isenção dos encargos da Conta de Desenvolvimento Energético (CDE) e do Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa), reduzindo a tarifa em parte. Assim, as distribuidoras são ressarcidas com fundos da Conta de Desenvolvimento Energético (CDE) na exata medida do benefício concedido.

## **1.1 Motivação**

O estudo do comportamento das diversas classes de consumidores é de fundamental importância para o bom planejamento do setor elétrico, e auxilia as concessionárias na tomada de decisão, na aquisição de energia nos leilões de energia realizados pela Agência Nacional de Energia Elétrica (ANEEL), para o atendimento de seus clientes cativos.

Frisamos ainda que o desenvolvimento regional é crucial para acelerar o crescimento econômico e social do Brasil e as desigualdades regionais travam avanços significativos na economia nacional, levando um atraso social e econômico para algumas regiões brasileiras.

Assim, o custo da energia para as famílias de baixa renda tem se tornado impactante nos orçamentos familiares, em particular nas regiões mais pobres do Brasil, resultando em condições de atraso no pagamento e ampliação das perdas comerciais das concessionárias.

Assim, o estudo de caso desta dissertação foi realizado em um estado do nordeste brasileiro e, considerando as desigualdades social e econômica existentes entre as diversas regiões brasileiras, a motivação recaiu sobre o consumidor residencial de baixa renda, buscando uma forma mais precisa de prever seu comportamento.

Dessa forma, tomando como objeto de estudo o Estado do Ceará, verificamos que, de todas as UC's, classificadas como consumidores residenciais, num total de 3.168.016, encontra-

se 41,68% classificadas como subclasse baixa renda (1.320.543), dados da ANEEL para julho de 2023, o que, de forma inequívoca, justifica a motivação. Lembrando que, desde 2010, estes consumidores são enquadrados segundo a Tarifa Social de Energia Elétrica (TSEE), lei n.º 12.212/2010, regulamentada pelo decreto n.º 7.583/2011.

Neste sentido, acreditamos que esta pesquisa contribuirá, tanto para que as concessionárias possam se adequar aos leilões de energia, como para que os órgãos governamentais possam melhorar as políticas públicas de inclusão social e de tarifas para estes consumidores.

## **1.2 Objetivos**

### ***1.2.1 Objetivos gerais***

Esta dissertação tem como objetivo geral realizar previsão da demanda de energia elétrica da classe de consumo Residencial e, dentro desta, a subclasse Baixa Renda, com o intuito de auxiliar as concessionárias no planejamento energético.

### ***1.2.2 Objetivos específicos***

1. Determinar do número de consumidores da subclasse Baixa Renda no Estado do Ceará, mês a mês dos anos de 2012 a 2012.
2. Montar as séries temporais do consumo e do número de consumidores.
3. Modelar e analisar a previsão de demanda utilizando métodos estatísticos: suavização exponencial, ARIMA e SARIMAX.
4. Analisar do comportamento de variáveis exógenas, como a tarifa de energia e o salário-mínimo nacional na previsão de demanda da subclasse Baixa Renda, no modelo SARIMAX.

## **1.3 Organização do trabalho**

Seguindo critérios metodológicos, dividimos este trabalho em cinco capítulos, somando-se esta introdução e nossas conclusões. Na introdução, são abordados assuntos sobre a importância do planejamento energético e das políticas públicas voltadas para esses consumidores. No capítulo 2, discorreremos sobre a caracterização da carga, mostrando a

classificação dos consumidores, a tipologia, o nível de tensão e as curvas.

No capítulo 3, explicamos os conceitos de séries temporais e apresentamos os modelos de previsões de demanda de energia elétrica.

O capítulo 4, por sua vez, é dedicado a nossa metodologia. Nele, indicamos quais os principais passos metodológicos percorridos e instrumentos utilizados para a realização deste trabalho. Vimos o estudo de caso e descrevemos a metodologia do uso dos modelos preditivos para demanda de energia elétrica, fazendo uma comparação entre eles. No capítulo 5, apresentamos e discutimos os resultados alcançados com as análises dos nossos dados, relacionando-os aos resultados obtidos por outros estudiosos aqui referendados e apresentando as possíveis propostas para a continuação desta pesquisa.

## 2 CARACTERIZAÇÃO DA CARGA

A energia elétrica é de fundamental importância para todos os setores produtivos e a sociedade em geral. Grande parte da população usufrui desse tipo de energia das mais variadas formas, conforme os seus objetivos e as suas finalidades na sociedade. Uns utilizam para benefício próprio, no caso das residências e condomínios, como conforto térmico (centrais de ar-condicionado, ventiladores, entre outros), lazer (assistir televisão com os familiares). Já outras camadas da sociedade utilizam a energia elétrica para gerar renda e capital, como o setor industrial, o qual utiliza um grande maquinário para a produção, que necessita de eletricidade para estar em pleno funcionamento. O setor comercial é outro que se utiliza de energia para gerar renda, desde máquinas frigoríficas, para conservar alimentos, até os caixas, para realizar pagamentos.

Devido a essa característica heterogênea da utilização da energia elétrica, foram criadas várias classes de consumo, as quais se definem, consoante a Resolução Normativa ANEEL n.º 414/2010, que sofreu uma revisão pela publicação da Resolução Normativa ANEEL n.º 1000/2021, a qual consolidou o conteúdo de 61 normas anteriormente publicadas pela ANEEL, revogadas e agregadas, parcialmente, ao conteúdo de três resoluções. Entre os principais pontos reunidos, estão:

- Contratação de energia elétrica por consumidor livre no Sistema Interligado Nacional (antiga REN 376/2009);
- Condições gerais de fornecimento de energia elétrica (antiga REN 414/2010);
- Ouvidoria (antiga REN 470/2011);
- Modelo e condições de atendimento de energia elétrica para comunidades isoladas (SIGFI / MIGDI, constava na antiga REN 493/2012);
- Condições de acesso ao sistema de distribuição (antiga REN 506/2012 + PRODIST 3);
- Bandeiras Tarifárias\_ Procedimentos comerciais (antiga REN 547/2013);
- Prestação de atividades acessórias pelas distribuidoras (antiga REN 581/2013);
- Modalidades de pré-pagamento e pós-pagamento eletrônico (antiga REN 610/2014);
- Aplicação da modalidade tarifária horária branca (antiga REN 733/2016);
- Recarga de veículos elétricos (antiga REN 819/2018) (ANEEL, 2022).

## 2.1 Classificação dos consumidores

Segundo a ANEEL, no parágrafo 5º da Resolução Normativa ANEEL n.º 1000/2021:

Para fins de aplicação tarifária, as unidades consumidoras devem ser classificadas de acordo com a atividade comprovadamente exercida, a finalidade de utilização da energia elétrica e o atendimento aos critérios para enquadramento previstos neste Capítulo e na legislação, em uma das seguintes classes tarifárias: residencial; industrial; comércio, serviços e outras atividades; rural; poder público; iluminação pública; serviço público e consumo próprio (ANEEL, 2021).

### 2.1.1 Residencial

Consoante a seção III, no Art. 176 da Resolução Normativa ANEEL n.º 1000/2021,

Deve ser classificada na classe residencial a unidade consumidora em imóvel utilizado para fins de moradia, com exceção da subclasse residencial rural, considerando-se as seguintes subclasses: residencial; residencial baixa renda; residencial baixa renda indígena; residencial baixa renda quilombola; residencial baixa renda benefício de prestação continuada da assistência social – BPC; residencial baixa renda multifamiliar (ANEEL, 2021).

A classe residencial possui uma tarifa monômnia que está enquadrada no grupo B; existem unidades consumidoras da classe residencial que estão no grupo A, também. Além disso, para atender aos critérios e se enquadrar na subclasse Baixa Renda, é necessário, segundo a seção III, no Art. 177 da Resolução Normativa ANEEL n.º 1000/2021:

- Família inscrita no Cadastro Único para Programas Sociais do Governo Federal (CadÚnico) com renda familiar mensal por pessoa menor, ou igual a meio salário-mínimo nacional;
- Idosos com 65 anos ou mais, ou pessoas com deficiência que recebam o Benefício de Prestação Continuada da Assistência Social (BPC), nos termos dos arts. 20 e 21 da Lei n.º 8.742, de 7 de dezembro de 1993;
- Família inscrita no Cadastro Único com renda mensal de até três salários-mínimos, que tenha portador de doença ou deficiência (física, motora, auditiva, visual, intelectual e múltipla) cujo tratamento, procedimento médico ou terapêutico, requeira o uso continuado de aparelhos, equipamentos ou instrumentos que, para o seu funcionamento, demandem consumo de energia elétrica (ANEEL, 2021).

A classificação nas subclasses residencial, baixa renda, indígena e quilombola depende

desses consumidores atenderem aos pré-requisitos mencionados anteriormente. Tendo preenchidos todos, os consumidores serão beneficiados com a Tarifa Social de Energia Elétrica (TSEE), que foi criada pela Lei n.º 10.438, de 26 de abril de 2002. Através dela, são concedidos descontos para os consumidores enquadrados na Subclasse Residencial Baixa Renda, custeados pela Conta de Desenvolvimento Energético (CDE) e pela isenção do Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa).

Além dessas isenções, no restante da tarifa residencial são aplicados os descontos, cumulativamente, conforme a tabela 1.

Tabela 1 - Descontos Consumidores Baixa Renda e Baixa Renda-BPC

<b>Baixa renda e Baixa renda-BPC</b>		
<b>Parcela de consumo mensal de energia elétrica</b>	<b>Desconto</b>	<b>Tarifa para aplicação da redução</b>
de 0 a 30 kWh	65%	B1 subclasse baixa renda
de 31 kWh a 100 kWh	40%	
de 101 kWh a 220 kWh	10%	
a partir de 221 kWh	0%	

Fonte: ANEEL (2022).

Em relação aos descontos, vale destacar que as famílias indígenas e quilombolas inscritas no Cadastro Único, que atendam aos requisitos, têm desconto de 100% até o limite de consumo de 50 kWh/mês (quilowatts-hora por mês), como mostra a tabela 2.

Tabela 2 - Descontos Consumidores Baixa Renda Quilombolas e Indígenas

<b>Quilombola e Indígena</b>		
<b>Parcela do consumo mensal de energia elétrica</b>	<b>Desconto</b>	<b>Tarifa para a aplicação da redução</b>
de 0 a 50 kWh	100%	B1 subclasse baixa renda
de 51 kWh a 100 kWh	40%	
de 101 kWh a 220 kWh	10%	
a partir de 221 kWh	0%	

Fonte: ANEEL (2022).

### **2.1.2 Industrial**

Consoante a seção IV, no Art. 180 da Resolução Normativa ANEEL n.º 1000/2021:

Na classe industrial enquadram-se as unidades consumidoras em que sejam desenvolvidas as seguintes atividades estabelecidas na Classificação Nacional de Atividades Econômicas – CNAE: industrial e transporte de matéria-prima, insumo ou produto resultante do seu processamento, caracterizado como atividade de suporte e sem fim econômico próprio, desde que realizado de forma integrada fisicamente à unidade consumidora industrial (ANEEL, 2021).

Segundo a EPE, no Boletim Trimestral de Consumo de Eletricidade de 2023, o setor de metalurgia apresentou o maior consumo de eletricidade na classe industrial, com um quarto de todo o consumo da classe (EPE, 2023).

Na classe industrial, as tarifas são aplicadas para o grupo A e para o Grupo B, no subgrupo B3, conforme definido pela ANEEL. Geralmente, os consumidores industriais se enquadram no grupo A, devido ao nível de tensão que são atendidos, acima de 2,3kV.

### ***2.1.3 Comércio, serviço e outras atividades***

Na seção V é definida a classe comercial, serviços e outras atividades, a qual, segundo o Art. 182 da Resolução Normativa ANEEL n.º 1000/2021, destaca:

Na classe comercial, serviços e outras atividades enquadram-se as unidades consumidoras onde sejam desenvolvidas as atividades de prestação de serviços e demais não previstas nas demais classes, dividindo-se nas seguintes subclasses: comercial; serviços de transporte, exceto tração elétrica; serviços de comunicações e telecomunicações; associação e entidades filantrópicas; templos religiosos; administração condominial: iluminação e instalações de uso comum de prédio ou conjunto de edificações; iluminação em vias: solicitada por quem detenha concessão ou autorização para administração de vias de titularidade da União ou dos Estados; semáforos, radares e câmeras de monitoramento de trânsito, solicitados por quem detenha concessão ou autorização para controle de trânsito e outros serviços e outras atividades (ANEEL, 2021).

Segundo o Boletim Trimestral de Consumo de Eletricidade de 2023, o setor comercial apresentou uma elevação do consumo de eletricidade no primeiro trimestre desse ano, decorrente ao bom comportamento do setor de vendas do varejo e do setor de serviços. As maiores contribuições das vendas foram oriundas do setor de hiper, supermercados, produtos alimentícios, bebidas e fumo; artigos farmacêuticos, médicos, ortopédicos e de perfumaria; livros, jornais, revistas e papelaria; tecidos, vestuários, calçados, móveis e eletrodomésticos. Por sua vez, o setor de serviços foi puxado por: serviços prestados às famílias; de informação e comunicação; setor de transportes e de profissionais. Administrativos e complementares foram os que mais podem ter favorecido o crescimento do consumo da classe (EPE, 2023).

Para a classe comercial, serviços e outras atividades, aplica-se as tarifas do grupo A e do grupo B, no subgrupo B3.



### 2.1.4 Rural

A classe de consumo rural é definida segundo a Resolução Normativa ANEEL n.º 1000/2021, no Art. 184 da seção VI, como:

As unidades consumidoras que desenvolvam as atividades dispostas nas seguintes subclasses:

I - Agropecuária rural: localizada na área rural, onde seja desenvolvida atividade relativa à agropecuária, classificada nos grupos 01.1 a 01.6 da CNAE, inclusive o beneficiamento ou a conservação dos produtos agrícolas oriundos da mesma propriedade e o fornecimento para:

a) instalações elétricas de poços de captação de água, para atender finalidades de que trata este inciso, desde que não haja comercialização da água; e

b) serviço de bombeamento de água destinada à atividade de irrigação.

II – Agropecuária urbana: localizada na área urbana, onde sejam desenvolvidas as atividades do inciso I, observados os seguintes requisitos:

a) a carga instalada na unidade consumidora deve ser predominantemente destinada à atividade agropecuária, exceto para os casos de agricultura de subsistência; e

b) o titular da unidade consumidora deve possuir registro de produtor rural expedido por órgão público ou outro documento hábil que comprove o exercício da atividade agropecuária.

III – residencial rural: localizada na área rural, com fim residencial, utilizada por trabalhador rural ou aposentado nesta condição;

IV – Cooperativa de eletrificação rural: localizada em área rural, que detenha a propriedade e opere instalações de energia elétrica de uso privativo de seus associados, cujas cargas se destinem ao desenvolvimento de atividade classificada como rural nos termos deste artigo, observada a legislação e os regulamentos aplicáveis;

V - Agroindustrial: independentemente de sua localização, desde que atenda os seguintes critérios: possuir atividade de indústria, transformar ou beneficiar produtos advindos diretamente da agropecuária, ainda que provenientes de outros imóveis, ser do Grupo B, desde que a potência posta à sua disposição seja menor ou igual a 112,5 kVA ou, se do Grupo A, possuir transformador com potência menor ou igual a 112,5 kVA;

VI – serviço público de irrigação rural: localizado na área rural em que seja desenvolvida a atividade de irrigação e explorado por entidade pertencente ou vinculada à Administração Direta, Indireta ou Fundações de Direito Público da União, dos Estados, Distrito Federal ou dos Municípios;

VII – escola agrotécnica: estabelecimento de ensino direcionado à agropecuária,

localizado na área rural, sem fins lucrativos e explorada por entidade pertencente ou vinculada à Administração Direta, Indireta ou Fundações de Direito Público da União, dos Estados, Distrito Federal ou dos Municípios.

VIII– aquicultura: independentemente de sua localização, onde seja desenvolvida atividade de cultivo de organismos cujo ciclo de vida em condições naturais se dá total ou parcialmente em meio aquático, disposta no grupo 03.2 da CNAE, sendo que o titular da unidade consumidora deve possuir registro de produtor rural expedido por órgão público, registro ou licença de agricultor, exceto para agricultura com fins de subsistência (ANEEL, 2021).

Para a classe rural, aplica-se as tarifas do grupo A e do grupo B, no subgrupo B2.

### ***2.1.5 Poder público***

Na classe do poder público, a Resolução Normativa ANEEL n.º 1000/2021 enquadra no Art. 187 da seção VII como:

As unidades consumidoras de responsabilidade de consumidor que seja pessoa jurídica de direito público, independentemente da atividade desenvolvida, incluindo a iluminação em vias e semáforos, radares e câmeras de monitoramento de trânsito, exceto aqueles classificáveis como serviço público de irrigação rural, escola agrotécnica, iluminação pública e serviço público, subdividindo-se nas seguintes subclasses: poder público federal; poder público estadual ou distrital e poder público municipal (ANEEL, 2021).

Da mesma maneira que as classes industrial e comercial, serviços e outras atividades, a tarifa aplicada nessa classe será a mesma do grupo A e do grupo B, subgrupo B3.

### ***2.1.6 Iluminação pública***

A classe de iluminação pública é definida pela Resolução Normativa ANEEL n.º 1000/2021, no Art. 189 da seção VIII, como:

As unidades consumidoras destinadas exclusivamente para a prestação do serviço público de iluminação pública, de responsabilidade do Poder Público Municipal ou Distrital, ou ainda daquele que receba essa delegação, com o objetivo de iluminar: vias públicas destinadas ao trânsito de pessoas ou veículos, tais como ruas, avenidas, logradouros, caminhos, passagens, passarelas, túneis, estradas e rodovias e bens públicos destinados ao uso comum do povo, tais como abrigos de usuários de transportes coletivos, praças, parques e jardins, ainda que o uso esteja sujeito a condições estabelecidas pela administração, inclusive o cercamento, a restrição de horários e a cobrança (ANEEL, 2021).

Dessa forma, as tarifas aplicadas a essa classe são as mesmas do grupo A e do grupo B, subgrupo B4a.

### ***2.1.7 Serviço público***

Nesta classe, a definição na seção IX, no Art. 191, da Resolução Normativa ANEEL n.º 1000/2021, feita da seguinte maneira:

Na classe serviço público enquadram-se as unidades consumidoras que se destinem, exclusivamente, ao fornecimento para motores, máquinas e cargas essenciais à operação de serviços públicos de água, esgoto, saneamento e tração elétrica urbana ou ferroviária, explorados diretamente pelo Poder Público ou mediante concessão ou autorização, considerando-se as seguintes subclasses: tração elétrica e água, esgoto e saneamento (ANEEL, 2021).

As cargas referentes a essa classe devem ser tarifadas conforme o grupo A ou o grupo B, no subgrupo B3.

### ***2.1.8 Consumo próprio***

Por último, mas não menos importante, está a classe de consumo próprio, a qual é definida pela Resolução Normativa ANEEL n.º 1000/2021, no Art. 53-T, da seção X que destaca:

Deve ser classificada na classe consumo próprio a unidade consumidora de titularidade da distribuidora, subdividindo-se nas seguintes subclasses: estação de recarga de veículos elétricos e outras atividades, aplicando-se as tarifas homologadas pela ANEEL para o Grupo A e, para o Grupo B, as tarifas homologadas do subgrupo B3 (ANEEL, 2021).

A tabela 3, mostra o consumo por classe em GWh do ano de 2012 ao ano de 2021, ilustrando a sua taxa de variação acumulada durante os anos e a participação em percentual de cada classe de consumo no Brasil.

Tabela 3 - Percentual do consumo de energia elétrica por classe de consumidores

Percentual do consumo de energia elétrica por classe										
Ano	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
<b>Brasil</b>	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
<b>Residencial</b>	26,25%	26,97%	27,86%	28,17%	28,77%	28,76%	28,93%	29,51%	31,09%	30,11%
<b>Industrial</b>	40,93%	39,88%	37,72%	36,35%	35,80%	35,83%	35,75%	34,75%	34,93%	36,25%
<b>Comercial</b>	17,68%	18,07%	18,92%	19,49%	19,03%	18,90%	18,63%	19,08%	17,32%	17,45%
<b>Rural</b>	5,12%	5,06%	5,41%	5,56%	5,90%	6,02%	6,24%	6,13%	6,65%	6,59%
<b>Poder Público</b>	3,14%	3,16%	3,23%	3,26%	3,27%	3,22%	3,17%	3,25%	2,68%	2,76%
<b>Ilum. Pública</b>	2,88%	2,92%	2,96%	3,29%	3,26%	3,31%	3,30%	3,28%	3,24%	2,82%
<b>Serv. Público</b>	3,24%	3,21%	3,21%	3,16%	3,24%	3,25%	3,32%	3,31%	3,43%	3,35%
<b>Cons. Próprio</b>	0,75%	0,73%	0,69%	0,71%	0,73%	0,70%	0,68%	0,68%	0,66%	0,67%

Fonte: EPE (2022)

## 2.2 Grupo de consumidores por nível de tensão

Segundo a Agência Nacional de Energia Elétrica (ANEEL), na Resolução Normativa ANEEL n.º 1000/2021, no capítulo 1 – Das Definições, as unidades consumidoras podem ser divididas de acordo os níveis de tensão em dois grupos:

•Grupo A: composto por unidades consumidoras com tensão igual ou superior 2,3 kV, possuem tarifa binômica e subdivide-se em:

- a) Subgrupo A1 - tensão de fornecimento igual ou superior a 230 kV;
- b) Subgrupo A2 - tensão de fornecimento de 88 kV a 138 kV;
- c) Subgrupo A3 - tensão de fornecimento 69 kV;
- d) Subgrupo A3a - tensão de fornecimento de 30 kV a 44 kV;
- e) Subgrupo A4 - tensão de fornecimento de 2,3 kV a 25 kV;
- f) Subgrupo AS - tensão de fornecimento menor que 2,3 kV, a partir de sistema subterrâneo de distribuição.

•Grupo B: é o grupo de unidades consumidoras com tensão inferior a 2,3 kV, o qual é caracterizado por ter uma tarifa monômica, e pode ser subdividido nos seguintes subgrupos:

- a) Subgrupo B1 – residencial;
- b) Subgrupo B2 – rural;
- c) Subgrupo B3 – demais classes;
- d) Subgrupo B4 – iluminação pública (ANEEL, 2021).

### 2.3 Consumidores por tipo de mercado

A Agência Nacional de Energia Elétrica (ANEEL) define como consumidor cativo todo aquele que compra energia elétrica da concessionária de eletricidade local, estando sujeito às tarifas homologadas pela própria ANEEL. Esse usuário está sujeito às revisões tarifárias que acontecem a cada 4 anos, e aos reajustes que ocorrem nos anos que não acontecem as revisões.

O consumidor cativo paga uma fatura de energia por mês, a qual possui tarifas reguladas pelo Governo, mais especificamente pela ANEEL, comporta por uma parcela referente ao consumo de energia elétrica e por outra que faz referência ao uso do sistema de distribuição (TUSD). Dessa forma, esse usuário está sujeito à riscos, e absorve as incertezas do setor elétrico, pois, dentro das suas tarifas está incluso o custo da transmissão de energia, serviço ofertado pelas transmissoras, das geradoras, que oferecem o serviço da geração e das distribuidoras, as quais são responsáveis pelo transporte até o consumidor. Portanto, esse tipo de consumidor não tem como gerenciar essas variáveis e, por isso, fica dependente do planejamento centralizado do governo, das geradoras, das transmissoras e das distribuidoras (ABRACEEL, 2023).

No caso dos consumidores livres, são definidos conforme a Resolução Normativa ANEEL n.º 1000/2021. Essa norma define Consumidor livre como: agente da CCEE, da categoria de comercialização, que adquire energia elétrica no ambiente de contratação livre para unidades consumidoras que satisfaçam, individualmente, os requisitos dispostos nos arts. 15 e 16 da Lei no 9.074, de 1995 (ANEEL, 2021).

Os consumidores livres compram energia das geradoras e dos comercializadores por meio de contratos bilaterais com as condições livremente negociadas. Essas negociações acontecem no Ambiente de Contratação Livre (ACL), aonde acontece uma livre negociação entre vendedores e compradores de energia, e o preço é estabelecido entre as partes. Além disso, é negociado também prazos, garantias financeiras, contratos de conexões e uso das instalações de distribuição e transmissão de energia. Para se tornar um consumidor livre, é preciso aderir à Câmara de Comercialização de Energia Elétrica (CCEE). Para isso, existem as seguintes etapas: análise da conta de energia do cliente, verificação do enquadramento da unidade consumidora no mercado livre, análise econômica da migração e as etapas da migração (CCEE, 2023).

Na análise da conta de energia, é feito um gerenciamento energético com o objetivo de verificar a eficiência energética das instalações e o custo da energia na unidade consumidora. Para participar do mercado de energia, todas as empresas de geração, distribuição e comercialização precisam ser associadas à Câmara de Comercialização de Energia Elétrica

(CCEE). Consumidores de alta tensão com demandas a partir de 0,5 MW também podem participar de negociações no Ambiente de Contratação Livre. Na análise econômica da migração, é feito um estudo para conhecer os custos, tanto do ambiente regulado, como do ambiente livre (CCEE, 2023).

Por último, nas etapas da migração estão: a contratação de energia no ambiente livre, onde é celebrado os contratos de comercialização de energia com empresas de comercialização ou de geração; a denúncia do contrato no mercado cativo, em que é feita a rescisão com a distribuidora do mercado, sendo verificado prazos de possíveis multas pela rescisão; a celebração de contratos CUSD e CCER, onde a distribuidora irá elaborar o Contrato de Uso do Sistema de Distribuição (CUSD); a solicitação de adesão à Câmara de Comercialização de Energia Elétrica (CCEE), em que o consumidor deve enviar o termo de adesão à CCEE; e a adequação do sistema de faturamento, onde vai ser todo projetado e direcionado à medição e o faturamento para um consumidor livre.

A decisão de ir para o mercado livre é individual de cada consumidor, e deve ser levado em consideração outros fatores como: as tarifas, a importância da energia para o processo produtivo, a capacidade de reduzir ou ampliar consumo, entre outros (ABRACEEL, 2023).

## **2.4 Características de curvas de carga**

O conceito de carga está relacionado com a potência elétrica consumida por determinada unidade consumidora. Segundo a Agência Nacional de Energia Elétrica (ANEEL), no módulo 1 do PRODIST, carga, é definida como “A caracterização da demanda do sistema, em um determinado ponto de interesse, definida por uma ou mais das seguintes grandezas: potência ativa, demanda de energia ativa e demanda de energia reativa” (ANEEL, 2022).


Levando em consideração que a demanda é uma média das potências ativas ou reativas durante um determinado intervalo de tempo, que a carga instalada em operação solicita ao sistema elétrico, poderá ser estimada, durante o intervalo de tempo de 24 horas, uma curva que mostre o comportamento dessas potências em uma unidade consumidora, a qual pode ser chamada de curva de carga.

De acordo com a Agência Nacional de Energia Elétrica (ANEEL), no módulo 1 do PRODIST, curva de carga é definida como “Registro horário, em um período diário, das demandas de capacidade, podendo ser, excepcionalmente, para período semanal, mensal ou anual”.

O gráfico 1 ilustra duas curvas de cargas, uma de um dia, sem nenhum evento de

relevância nacional (em azul), e outra no dia do jogo da Seleção Brasileira contra a Seleção da Bélgica pela Copa do Mundo 2018 (em vermelho).

Gráfico 1 - Curva de carga no dia do jogo do Brasil pela Copa do Mundo 2018

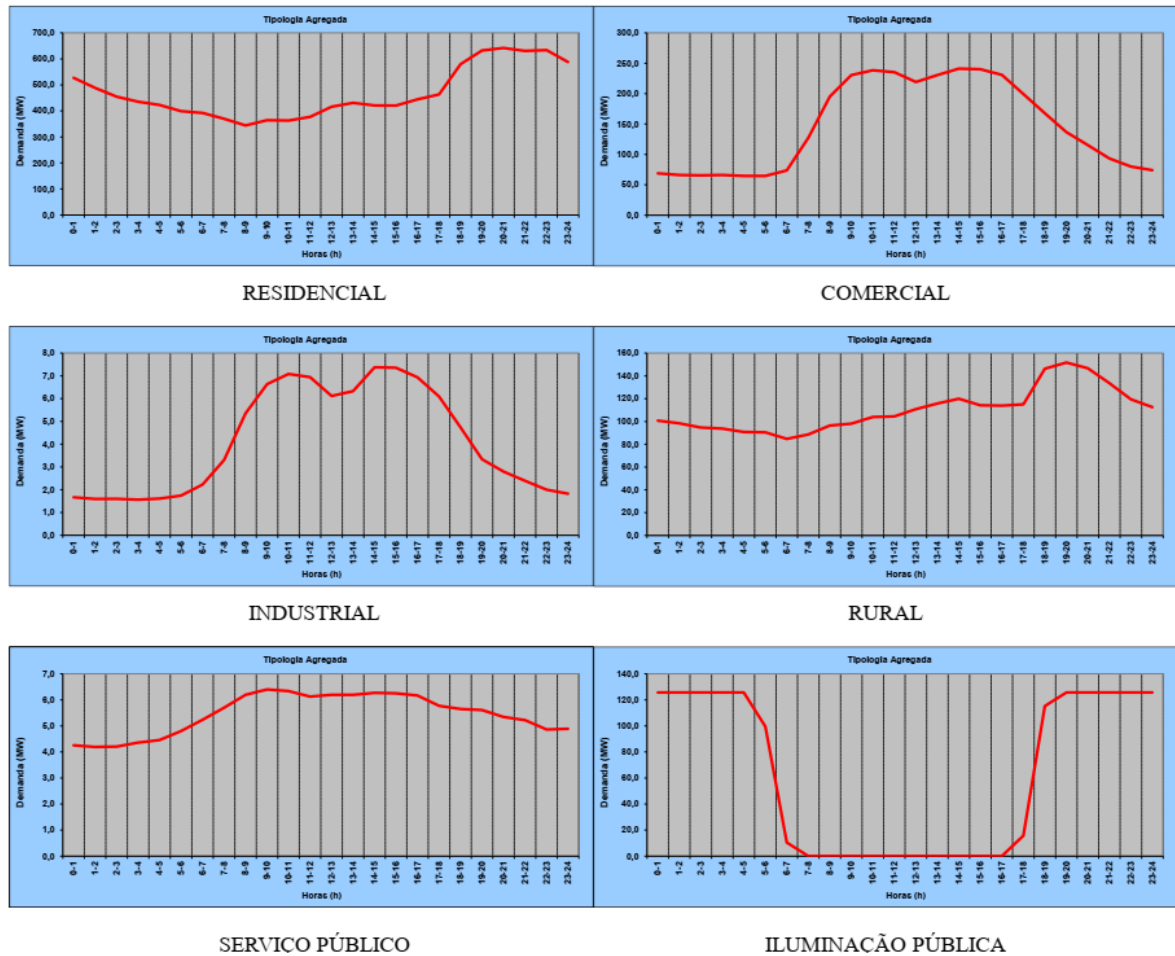


Fonte: ONS (2018).

Cerca de duas horas antes de começar a partida, houve uma redução na carga de 8613 MW, com o início do jogo, houve mais uma redução da carga de 2303 MW em 20 minutos, com o intervalo, ocorreu uma elevação de 2398 MW em 8 minutos, no início do segundo tempo, a carga foi reduzida, novamente, em 1565 MW e, com o final da partida, houve uma elevação na carga de 7188 MW (ONS, 2018).

É possível perceber, através de uma curva de carga, a influência que um evento como a Copa do Mundo traz, pois a mobilização da população é a nível nacional, e os hábitos do cotidiano mudam. Nessa situação, as pessoas saíram mais cedo do trabalho e se prepararam, horas antes de começar o jogo, para assistir à partida, por isso, a redução de carga no intervalo de 12h45min até o início da partida às 15h. O gráfico 2 mostra as curvas de cargas horárias por classes de consumo no Estado do Ceará, revelando a diferença no perfil de consumo de cada consumidor.

Gráfico 2 - Curvas de carga por classe de consumo no estado do Ceará



Fonte: (DAIMON ENGENHARIA E SISTEMAS, 2018)

Esta identificação do perfil de consumo auxilia a concessionária de energia no momento de definir as tarifas, sendo necessário tarifas diferentes, conforme cada grupo de consumidores. Na classe de consumo comercial e industrial, os maiores valores de consumo ocorrem durante o período de 6h até às 17h, que corresponde ao horário de expediente de trabalho nos estabelecimentos comerciais e nas indústrias. Um perfil de consumo totalmente diferente da classe de iluminação pública, com um consumo praticamente constante entre o período de 18h às 5h, justamente no período da noite, onde as luminárias ficam acesas. Um perfil de consumo diferente necessita de tarifas diferentes, tudo isso, com o intuito de conseguir a modicidade tarifária.



### 3 MODELOS DE PREVISÃO DE CARGA

Os modelos de previsão dependem muito da quantidade dos dados disponíveis, da grandeza a qual se quer fazer a previsão, de como esses dados estão agrupados, de valores “*outliers*” e de outros fatores. Existem métodos de previsão qualitativos e quantitativos, o primeiro é composto por abordagens bem estruturadas, desenvolvidas para fazer a previsão sem utilizar dados históricos; e o segundo utiliza dados históricos, geralmente, de séries temporais.

Neste trabalho foram utilizados métodos quantitativos de previsão, usando dados de uma série temporal que, geralmente, são os mais utilizados. Importante ressaltar que, cada método tem suas particularidades, precisão e custos, os quais devem ser considerados, quando escolhidos para determinado objetivo (HYNDMAN e ATHANASOPOULOS, 2021).

Velasquez (2022) utilizou os modelos: ARIMA, Suavização Exponencial e Regressão com Sazonalidade para prever a demanda do Brasil de eletricidade, considerando a média mensal no período de janeiro de 2002 à dezembro de 2020. Para esses autores, a combinação de modelos preditivos pode reduzir o erro e aumentar a precisão na previsão em relação a análise, separadamente de apenas um modelo.

Nafil (2020) também trabalhou com os modelos: ARIMA e Suavização Exponencial para prever o consumo de eletricidade no Marrocos, mas, ele acrescentou uma modelagem de causalidade temporal (Causalidade de Granger), objetivando subsidiar o setor público e privado do país na área de planejamento energético.

Desses três modelos, o que obteve melhor desempenho nessa aplicação foi a modelagem de causalidade temporal (Causalidade de Granger), com uma diferença média entre os valores previstos e reais em torno de 0,404%.

A abordagem de séries temporais, conforme Elsaraiti (2021), deu ênfase ao modelo ARIMA, que foi utilizado para prever a demanda de eletricidade em Trípoli, na Líbia, utilizando dados de consumo diário, no período de janeiro a março de 2016 (12 semanas). Esse modelo apresentou bastante eficiência e precisão, obtendo somente um erro percentual médio absoluto (MAPE) de 4,332%, demonstrando a sua capacidade de competir com as técnicas atuais de previsão.

Conforme o estudo de Noureen (2019), uma análise de séries temporais, utilizando o modelo ARIMA, para uma carga agrícola de pequena escala, apresenta resultados bastantes satisfatórios.

Araújo (2023) utilizou as variações do modelo ARIMA para realizar a previsão de consumo de eletricidade na região Nordeste do Brasil, como o SARIMA e o SARIMAX. Além

disso, também utilizou a Suavização Exponencial, para realizar as previsões por meio do Modelo de Holt-Winters. E, dentre os três, o melhor desempenho apresentado foi o modelo SARIMA.

Amaral (2020) também utilizou o modelo de Suavização Exponencial de Holt e o modelo ARIMA para realizar a previsão de demanda de energia elétrica na região Sul do Brasil. Os resultados obtidos mostraram que os modelos foram capazes de se ajustar, adequadamente, aos dados, apresentando um erro sempre abaixo de 8,9% entre os valores reais e previstos.

### 3.1 Séries Temporais

Segundo Morettin e Tolói (2018), uma série temporal pode ser definida como qualquer conjunto de observações ordenadas no tempo. São exemplos de séries temporais:

- Lucro anual do Google;
- Vendas semanais no varejo;
- Demanda mensal de eletricidade;
- Preços diários das ações da Petrobras;
- Precipitação atmosféricas anual na cidade de Fortaleza;
- Registro de marés no porto de Santos.

As análises de séries temporais são feitas a partir de duas perspectivas, ambas, visando construir modelos para as séries, com um objetivo bem definido. Na primeira perspectiva, a análise é feita no domínio temporal, e os modelos propostos são paramétricos (com determinado número de parâmetros). Na segunda, a análise é feita no domínio de frequências, e os modelos propostos são modelos não paramétricos. O modelo ARIMA, que será estudado nesse trabalho, é um exemplo (MORETTIN e TOLÓI, 2018).

Tudo o que é observado, sequencialmente, ao longo do tempo, é uma série temporal, por exemplo, de hora em hora, diariamente, semanalmente, mensalmente, trimestralmente, anualmente. Ao prever dados de séries temporais, o objetivo é estimar como a sequência de observações continuará no futuro, baseado na análise dos dados do passado (HYNDMAN e ATHANASOPOULOS, 2021).


A análise de séries temporais é muito importante na economia para acompanhamento de PIB, oferta e demanda, dentre outras análises. Além disso, constitui-se em componente fundamental para o acompanhamento de fenômenos da natureza, em análise demográfica, em marketing, nas áreas de controle de qualidade e da saúde. Sendo assim, uma ferramenta de

grande utilidade para a ciência de dados.

A análise de séries temporais, como o próprio nome indica, é a investigação de variáveis observadas ao longo do tempo, com a pretensão de realizar previsões para períodos futuros (SOUSA, SILVA, *et al.*, 2021).

O gráfico 3 mostra a série temporal do consumo de energia elétrica na classe residencial, por mês, no Estado do Ceará, entre os anos de 2004 e 2021.

Gráfico 3 - Consumo de energia elétrica na classe residencial no estado do Ceará




Fonte: Elaborado pelo autor, com base em dados da EPE.

Uma série temporal é composta por três componentes: Tendência, Sazonalidade e Ruído, podendo ser decomposta para que seja feita uma análise mais detalhada do seu comportamento (HYNDMAN e ATHANASOPOULOS, 2021).

$$Z_t = T_t + S_t + E_t \quad (3.1)$$

Onde  $Z_t$  é a série temporal observada em um período  $t$ ,  $T_t$  é a componente tendência no período  $t$  e  $E_t$  é a componente de erro ou, também, conhecida como resíduo ou ruído, mesmo período  $t$ . O gráfico 4 mostra a série temporal do gráfico 3, decomposta em cada uma dessas componentes.

Gráfico 4 - Decomposição da série temporal do consumo de energia elétrica na classe residencial no Ceará



Fonte: Elaborado pelo autor, com base em dados da EPE.

É mostrado, primeiramente, a série temporal original, seguida por sua componente de tendência, de sazonalidade e de ruído, na respectiva ordem. A componente de tendência pode ser observada quando a série temporal seguir uma determinada direção, apresentando crescimento ou decrescimento, sendo não, necessariamente, linear, como na série histórica, mostrada no gráfico 3, que apresenta uma tendência de crescimento em certos períodos e, em outros, apresenta decrescimento. Em relação à sazonalidade, é observada quando um padrão se repete, com uma certa periodicidade, em um período específico (semana, mês, etc.), no gráfico acima é possível notar picos e declínios ao longo dos meses.


A componente de resíduos é determinada como tudo que não representar uma tendência ou sazonalidade, são erros aleatórios. Quando o resíduo, em uma série temporal, é muito grande, pode se tornar difícil identificar tendência ou sazonalidade, dificultando os modelos de previsão.

Outro conceito relacionado à séries temporais é o de estacionariedade, o qual significa que a série se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de estabilidade. Entretanto, a maioria das séries não são estacionárias, sendo necessário fazer diferenciações com o objetivo de torná-las, pois a grande parte dos procedimentos de análise estatística de séries temporais supões que estas sejam estacionárias. A classe dos modelos ARIMA descrevem muito bem séries temporais estacionárias e não estacionárias (MORETTIN e TOLÓI, 2018).

Também é importante, no estudo de séries temporais, o conceito de Autocorrelação. Se a Correlação mede o grau de relação entre duas variáveis diferentes, a Autocorrelação mede o grau de relação entre duas observações de uma mesma variável, observado no tempo, como, por exemplo, os preços de ações no mercado financeiro, observados, atualmente, que dependem do preço das ações no dia anterior.

O gráfico 5 mostra a função de autocorrelação da série temporal do consumo de energia elétrica na classe residencial, por mês, no Estado do Ceará entre os anos de 2004 e 2021.

Gráfico 5 - Gráfico da função de autocorrelação da série temporal do consumo de energia elétrica na classe residencial por mês no estado do Ceará entre os anos de 2004 e 2021



Fonte: Elaborado pelo autor, com base em dados da EPE.

Analisando o gráfico, podemos observar um decrescimento lento na autocorrelação, em relação ao tempo, dando um forte indicativo de que essa série não é estacionária, necessitando de alguma transformação para torná-la.

Apesar de ser possível identificar a estacionariedade de uma série temporal por meio do gráfico da função de autocorrelação, o método mais utilizado é o teste de raiz unitária de Dickey-Fuller Aumentado (ADF) ou o teste KPSS de Kwiatkowski, que inverte a hipótese nula do teste ADF. Esses testes surgiram pela necessidade de verificação se uma série temporal é ou não estacionária, precisando ou não de uma diferenciação para transformá-la.

## 3.2 Modelos preditivos

### 3.2.1 Suavização exponencial

A suavização exponencial foi proposta como um modelo preditivo de grande sucesso no final da década de 1950 (Brown, 1959; Holt, 1957; Winters, 1960), e motivou outros modelos muito bem-sucedidos. As previsões realizadas que utilizaram os métodos de suavização exponencial são médias ponderadas de observações anteriores, com os pesos decaindo exponencialmente, à medida que as observações ficam mais antigas. Ou seja, quanto mais recente a observação, maior o peso associado. Esse modelo gera previsões confiáveis, rapidamente e, para uma ampla gama de séries temporais, o que é uma grande vantagem, e de grande importância para aplicações na indústria (HYNDMAN e ATHANASOPOULOS, 2021).

Em séries temporais, especificamente, componentes como tendência e sazonalidade devem ser estimados para que previsões sejam realizadas. Dessa forma, métodos de suavização são extremamente úteis para identificar e remover tais efeitos, reduzindo a influência das componentes de tendência e sazonalidade, e produzindo séries estacionárias. O método mais simples, conhecido como Suavização Exponencial Simples (SES), é adequado para previsão de séries temporais livres, das componentes de tendência e sazonalidade (BARROS, MATTOS, *et al.*, 2018).

O método SES é descrito da seguinte forma:

$$\bar{Z}_t = \alpha Z_t + \alpha(1 - \alpha)Z_{t-1} + \alpha(1 - \alpha)^2 Z_{t-2} + \dots \quad (3.2)$$

Onde  $\bar{Z}_0 = Z_1$ ,  $t = 1$  e  $\alpha$  representa o parâmetro de suavização que varia entre valores

de 0 e 1. Quanto menor for o parâmetro  $\alpha$ , mais estáveis serão as previsões, isto é, as observações passadas terão pesos maiores do que teriam, no caso de  $\alpha$  grande. Por outro lado, se  $\alpha$  for próximo de 1, há um pequeno amortecimento e  $\bar{Z}_t$  é aproximadamente igual a  $Z_t$ . A principal vantagem do método SES é dada pela sua simplicidade de implementação e por não necessitar de uma grande quantidade de informações do histórico (BARROS, MATTOS, *et al.*, 2018).

O modelo de Suavização Exponencial Simples (SES) não é apropriado para séries que apresentam tendência linear, já que uma possível aplicação do modelo SES iria gerar previsões que subestimariam ou superestimariam continuamente os valores reais da série. Para contornar tal problema, o modelo de suavização exponencial de Holt (SEH), estendido por Holt em 1957, permite realizar previsões, levando em consideração o efeito de tendência linear.

O modelo SEH é similar ao modelo SES, com a diferença de que existirá um novo parâmetro de suavização para trabalhar diretamente com a tendência da série. Seus valores serão estimados por:

$$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.3)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.4)$$

Onde  $L_t$  estima o nível da série no tempo  $t$ ,  $T_t$  estima a tendência no tempo  $t$  e  $\alpha$  e  $\beta$  são, respectivamente, os parâmetros de suavização para o nível da série e tendência, com valores compreendidos no intervalo de 0 a 1 (BARROS, MATTOS, *et al.*, 2018).

A previsão para  $\bar{Z}_{t+h}$  é dada por:

$$\hat{Z}_h = L_t + h\hat{T}_t \quad (3.5)$$

A previsão é feita adicionando o valor encontrado na equação do nível  $L_t$  com o valor estimado para tendência  $\hat{T}_t$  multiplicado pelo número de passos à frente  $h$  que se deseja prever.

Entretanto, o modelo de suavização exponencial mais completo, que é capaz de considerar os efeitos das componentes de tendência e sazonalidade em uma série temporal, é o modelo de Holt-Winters. Este, é uma extensão feita por Winters em 1960, ao modelo proposto por Holt em 1957, com o intuito de capturar o efeito sazonal. O modelo segue a mesma proposta de equação vista na seção anterior, com a diferença da existência de uma equação adicional para a sazonalidade. Ele é semelhante ao método SEH, no entanto, o modelo de Suavização

Exponencial Holt-Winters (SEHW) é adequado para séries de comportamento mais geral, uma vez que, na prática, a maioria das séries encontradas apresentam a componente de sazonalidade.

Existem dois diferentes métodos de análise por SEHW, que se diferenciam através do modo que a sazonalidade será modelada, isto é, a sazonalidade pode receber um tratamento aditivo ou multiplicativo (BARROS, MATTOS, *et al.*, 2018).

Na forma aditiva, o modelo de HW é dado da seguinte forma:

$$L_t = \alpha(Z_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad 0 \leq \alpha \leq 1; t = m + 1 \quad (3.6)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad 0 \leq \beta \leq 1; t = m + 1 \quad (3.7)$$

$$S_t = \gamma(Z_t - L_{t-1} - T_{t-1}) + (1 - \gamma)S_{t-m} \quad 0 \leq \gamma \leq 1; t = m + 1 \quad (3.8)$$

$$\hat{Z}_h = L_t + hT_t + S_{t+h-m} \quad (3.9)$$

Onde  $\alpha$ ,  $\beta$  e  $\gamma$  são respectivamente os parâmetros de suavização para o nível da série, tendência e sazonalidade, e estão compreendidos no intervalo entre 0 e 1.

O modelo multiplicativo é dado por:

$$L_t = \alpha\left(\frac{Z_t}{S_{t-m}}\right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad 0 \leq \alpha \leq 1; t = m + 1 \quad (3.10)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad 0 \leq \beta \leq 1; t = m + 1 \quad (3.11)$$

$$S_t = \gamma\left(\frac{Z_t}{L_{t-1} - T_{t-1}}\right) + (1 - \gamma)S_{t-m} \quad 0 \leq \gamma \leq 1; t = m + 1 \quad (3.12)$$

$$\hat{Z}_h = (L_t + T_t h)S_{t+h-m} \quad (3.13)$$

Pode-se observar que as equações para a tendência são as mesmas em ambos os métodos, mudando apenas quando as equações apresentam componente sazonal. Nessa situação, estas equações aparecem com operações de multiplicação e divisão ao invés de soma e subtração (BARROS, MATTOS, *et al.*, 2018).

### 3.2.2 ARIMA

Juntamente com os modelos de Suavização Exponencial, os modelos ARIMA são os mais utilizados na previsão de séries temporais, fornecendo uma abordagem diferente. Enquanto os modelos de suavização exponencial são baseados em uma descrição da tendência e sazonalidade dos dados, os modelos ARIMA visam descrever as autocorrelações nos dados



(HYNDMAN e ATHANASOPOULOS, 2021).

Um modelo ARIMA é derivado de um modelo ARMA, o qual é um modelo autorregressivo de médias móveis, e o ARIMA é autorregressivo integrado de médias móveis. Além disso, podem ser citados os modelos AR, que são os modelos autorregressivos. Modelos ARIMA são aplicados a modelos estacionários e podem ser representados pela equação 3.14 (SOUSA, SILVA, *et al.*, 2021).

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (3.14)$$

Onde  $\phi(B)$  e  $\theta(B)$  são polinômios de ordem  $p$  e  $q$  que representam o operador autorregressivo e o operador de médias móveis, respectivamente,  $\Delta^d$  é o operador de diferenciação não sazonal e  $a_t$  é um parâmetro da parte autorregressiva do modelo. Uma metodologia muito utilizada na análise de séries temporais com os modelos ARIMA é a metodologia de Box e Jenkins, que consiste em ajustar modelos autorregressivos integrados de médias móveis, ARIMA ( $p, d, q$ ), a um determinado conjunto de dados. A estratégia para a construção do modelo é baseada em um ciclo iterativo, na qual a escolha da estrutura do modelo se adapta ao conjunto de dados utilizados (MORETTIN e TOLÓI, 2018).

As etapas do ciclo iterativo são:

- a) uma classe geral de modelos é considerada para a análise, no caso os modelos ARIMA (*especificação*);
- b) há *identificação* de um modelo, com base na análise de autocorrelações, autocorrelações parciais e outros critérios;
- c) a seguir vem a fase de *estimação*, na qual os parâmetros do modelo identificado são estimados;
- d) finalmente, há *verificação* ou *diagnóstico* do modelo ajustado, por meio de uma análise de resíduos, para se saber se este é adequado para os fins em vista (previsão, por exemplo) (MORETTIN e TOLÓI, 2018).

Caso o modelo não seja o adequado, o ciclo é repetido, voltando-se a fase de identificação. Algo que acontece muitas vezes é identificar não só um único modelo, mas, alguns que serão então estimados e verificados. Se o objetivo é previsão, serão escolhidos os modelos que melhor se encaixam na aplicação (MORETTIN e TOLÓI, 2018).

De acordo com os autores, existem três formas de representar o modelo ARIMA:

- a) em termos de valores prévios de  $Z_t$  e do valor atual e prévio de  $a_t$ ;
- b) em termos do valor atual e prévio de  $a_t$ ;

c) em termos de valores prévios de  $Z_t$  e do valor atual de  $a_t$ .

Entretanto, a forma mais usual de representar o modelo ARIMA, em forma de equação, é no modelo de Equação de Diferenças, útil para calcular previsões (MORETTIN e TOLÓI, 2018).

A Forma de Equação de Diferenças é dado da seguinte maneira:

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_{p+d} Z_{t-p-d} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.15)$$

$$\varphi(B) = 1 - \varphi_1 B + \varphi_2 B^2 - \dots - \varphi_{p+d} B^{p+d} \quad (3.16)$$

Onde  $\varphi(B)$  é o operador autorregressivo e um polinômio de ordem  $p$ , e  $B$  é o operador de defasagem.

O processo de identificação é a fase mais crítica do modelo ARIMA, ela é feita baseada nas autocorrelações (FAC) e autocorrelações parciais (FACP). O objetivo da identificação é determinar os valores de  $p$ ,  $d$  e  $q$  do modelo ARIMA ( $p$ ,  $d$ ,  $q$ ) (MORETTIN e TOLÓI, 2018).

O procedimento de identificação consiste de três partes:

1. Verificar se existe necessidade de uma transformação na série original, com o objetivo de estabilizar sua variância. Tal identificação pode ser realizada utilizando o auxílio de gráficos.
2. Tomar diferenças da série obtida na etapa anterior tantas vezes quantas necessárias para obter uma série estacionária, lembrando que uma série temporal é dita estacionária quando se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável, de modo que o processo seja reduzido a um modelo ARMA ( $p$ ,  $q$ ). O número de diferenças,  $d$ , necessárias para que o processo se torne estacionário é alcançado quando a FAC decresce rapidamente para zero.
3. Identificar o processo ARMA ( $p$ ,  $q$ ) resultante, mediante a análise das autocorrelações e autocorrelações parciais estimadas, cujos comportamentos devem imitar os comportamentos das respectivas quantidades teóricas (MORETTIN e TOLÓI, 2018).

Nesse momento do ciclo, a utilização de um teste para verificar a existência de raízes unitárias é de grande utilidade, por isso, foram mencionados anteriormente os testes de Dickey-Fuller Aumentado (ADF) e o teste KPSS de Kwiatkowski, que são utilizados para isso.

Após identificar a ordem do modelo ARIMA que será utilizado, será necessário estimar

os parâmetros desse modelo. Um dos métodos matemáticos que pode ser utilizado para essa estimativa de parâmetros é o Método da Máxima Verossimilhança (MMV). Esse método matemático consiste em encontrar os valores dos parâmetros que maximizam a probabilidade de obtenção dos dados que observamos. Para modelos ARIMA, o Método da Máxima Verossimilhança é semelhante às estimativas de mínimos quadrados (MORETTIN e TOLÓI, 2018).

O MMV é uma das maneiras usadas para se obter estimadores, pois desenvolve o problema de estimação com base nos resultados obtidos pela amostra, e deve-se determinar qual é a distribuição, entre todas aquelas definidas pelos possíveis valores de seus parâmetros, com maior probabilidade de ter gerado tal amostra (MORETTIN e TOLÓI, 2018).

Após estimar o modelo, é preciso verificar se ele representa ou não adequadamente os dados, qualquer insuficiência revelada pode sugerir um modelo alternativo como adequado. Uma técnica que pode ser utilizada, caso um modelo mais elaborado (contendo mais parâmetros) seja necessário, é o *superajustamento*. Um modelo com parâmetros extras é estimado e é examinado se estes parâmetros extras são significativos, bem como se sua inclusão diminui significativamente a variância residual (MORETTIN e TOLÓI, 2018).

Nesta etapa, é necessário analisar as características dos resíduos:

1. Ausência de autocorrelação linear;
2. Ausência de heterocedasticidade condicional;
3. Normalidade.

Existem alguns testes para verificar a adequação do modelo, como por exemplo:

- a) Teste de autocorrelação residual:** Tem como objetivo observar o comportamento de ruído branco nos resíduos, o qual consiste em uma série temporal que tenha seus dados não-correlacionados, média zero e variância constante.
- b) Teste de Box-Pierce-Ljung:** Esse teste não consegue identificar um desvio do comportamento padrão de ruído branco, porém, pode identificar se os resíduos estão muito altos. É verificado se existe diferença significativa entre a amostra e a população de referência.
- c) Teste da autocorrelação cruzada:** É uma medida de similaridade entre dois sinais em função de um atraso aplicado a um deles. Na relação entre duas séries temporais, uma delas pode estar relacionada com a outra por uma diferença de passo. É útil para identificar defasagens da variável, atrasos ou avanços, que podem ser preditores úteis da série principal.

Geralmente, em análise de dados, há uma escolha de muitos parâmetros com o objetivo de aumentar a precisão do modelo preditivo, porém, quando há esse aumento de forma exacerbada, existe o risco de surgir um fenômeno chamado de *overfitting* (excesso de ajuste ao conjunto de dados). Portanto, para se estimar os parâmetros  $p$ ,  $d$  e  $q$ , além de  $P$ ,  $D$  e  $Q$ , em caso de série sazonal, procurando evitar a adição exagerada de variáveis aos modelos, faz-se uso de critérios que, além de levarem em conta a qualidade do ajuste, penalizam o número de parâmetros, como, por exemplo, o Critério de Informação de Akaike, ou AIC (*Akaike's Information Criterion*) e o Critério de Informação Bayesiano, BIC (*Bayesian Information Criterion*).

### 3.2.3 SARIMAX

Os modelos ARIMA ( $p, d, q$ ) são um aprimoramento dos modelos ARMA ( $p, d$ ), pois, apesar de os modelos ARMA ( $p, d$ ) ser suficiente para a análise de séries temporais, os modelos ARIMA ( $p, d, q$ ) oferecem uma análise mais completa, ao considerar a tendência. Isso, devido aos modelos ARIMA ( $p, d, q$ ) terem a componente  $d$  que corresponde ao número de diferenciações da série temporal em análise, a qual faz com que a série seja transformada em estacionária (MORETTIN e TOLÓI, 2018).

Além disso, há mais um aprimoramento dentro da classe de modelos ARIMA ( $p, d, q$ ), o qual é o modelo SARIMAX ( $p, d, q$ ) ( $P, D, Q$ ), que consiste em um método ARIMA ( $p, d, q$ ), com uma componente que leva em consideração a sazonalidade, e outra que acrescenta uma variável exógena, com o intuito de verificar a sua influência na previsão da série temporal em análise. Essa variável exógena também pode ser chamada de variável explicativa porque ajuda a descrever a sua relação com a série temporal da aplicação. As equações referentes ao modelo SARIMA ( $p, d, q$ ) ( $P, D, Q$ ) estão representadas a seguir.

$$\phi(B)\Phi(B^S)\Delta^d\Delta_s^D X_t = \theta(B)\Theta(B^S)\varepsilon_t \quad (3.16)$$

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (3.17)$$

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (3.18)$$

$$\Phi(B^S) = 1 - \Phi_1 B^S - \dots - \Phi_P B^{SP} \quad (3.19)$$

$$\Theta(B^S) = 1 - \Theta_1 B^S - \dots - \Theta_Q B^{SQ} \quad (3.20)$$

Onde (3.16) é a equação original; (3.17) é o operador autorregressivo estacionário de

ordem  $p$ ; (3.18) é o operador de médias móveis invertível estacionário de ordem  $q$ ; (3.19) é o operador autorregressivo sazonal de ordem  $P$  estacionário; (3.20) é o operador de médias móveis sazonal de ordem  $Q$  invertível;  $\Delta = (1 - B)$ , que é o operador diferença;  $\Delta^d = (1 - B)^d$ , que é o operador diferença com  $d$  indicando o número de diferenciações;  $\Delta_s = (1 - B^s)$ , o qual é o operador diferença sazonal e  $\Delta_s^D = (1 - B^s)^D$ , onde  $D$  indica o número de diferenciações na parte sazonal (MORETTIN, 2017).

A equação (3.21) descreve o modelo SARIMAX ( $p, d, q$ ) ( $P, D, Q$ ), que corresponde a um modelo ARIMA ( $p, d, q$ ) com uma componente sazonal e outra referente a uma variável exógena (explicativa).

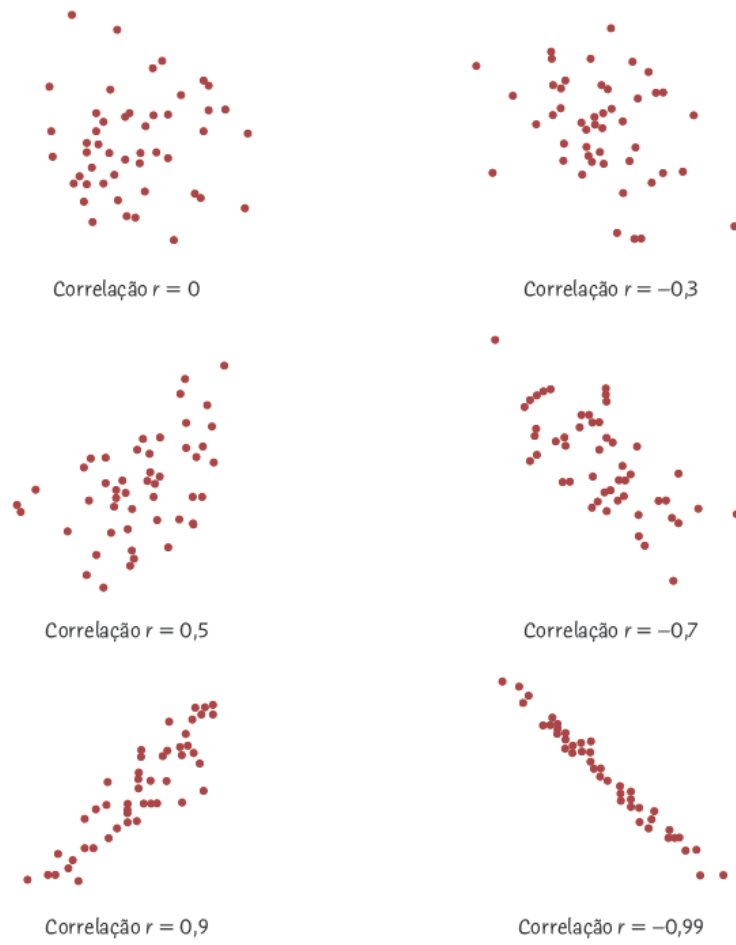
$$X_t = F(y) - \left( \frac{\Theta(B^s)\theta(B)\varepsilon_t}{\Phi(B)\phi(B)(1 - B)^d(1 - B^s)^D} \right) \quad (3.21)$$

Onde a função  $F(y)$  pode representar vários modelos, como um método de regressão ou uma função de variáveis *dummies*, que são usadas na classificação de dados. Na escolha da variável exógena, é recomendável verificar o grau de correlação entre ela e a série temporal analisada, pois, quanto maior o grau de correlação, melhor será a explicação dela. Por isso, utiliza-se o coeficiente de correlação de Pearson, que mede a força de relação linear entre duas variáveis e pode ser dado por:

$$r = \left( \frac{\sum(x_t - \bar{x})(y_t - \bar{y})}{\sqrt{\sum(x_t - \bar{x})^2} \sqrt{\sum(y_t - \bar{y})^2}} \right) \quad (3.22)$$

Onde o valor de  $r$  fica em um intervalo de -1 até 1, com valores negativos indicando uma correlação negativa e valores positivos indicando uma correlação positiva,  $x_t$  e  $y_t$  são os valores das observações de cada variável e  $\bar{x}$  e  $\bar{y}$  são as médias de cada variável. Os gráficos da Figura 1 mostram exemplos de conjuntos de dados com vários níveis de correlação.

Figura 1 - Exemplos de conjuntos de dados com diferentes níveis de correlação



Fonte: (MOORE, NOTZ e FLINGER, 2017)

## 4 ESTUDO DE CASO

### 4.1 Séries temporais utilizadas

O objetivo dessa dissertação é realizar a previsão do consumo médio dos consumidores residenciais baixa renda, com o intuito de subsidiar as tomadas de decisões da concessionária de energia nos leilões realizados pela ANEEL, fornecendo, com maior precisão, informações acerca do quanto de energia elétrica deverá ser contratado para suprir a área de concessão dessa concessionária.

O conjunto de dados analisados é referente às séries temporais: do consumo e do consumo médio de energia elétrica da classe residencial na subclasse baixa renda no Estado do Ceará, do número de consumidores da classe residencial na subclasse baixa renda, da tarifa de aplicação dessa classe de consumo e do salário mínimo, entre o período de janeiro de 2012 à dezembro de 2021 (10 anos).

Assim, foi gerada uma tabela com seis colunas: a primeira referente à Data; a segunda de Consumo; a terceira de Consumidores; a quarta de Consumo Médio, que foi obtida por meio do quociente do Consumo pelo número de Consumidores multiplicado por 1000 para que o valor fosse encontrado em kWh; a quinta de Tarifa e a sexta do Salário Mínimo; totalizando cinco séries temporais organizadas em uma tabela com auxílio do software Excel da Microsoft.

A tabela 4 mostra as primeiras 12 amostras de cada grandeza de um total de 120 observações com as cinco séries temporais. Essa tabela foi gerada através de dados de consumo disponíveis no site da EPE, de tarifas e de número de consumidores no site da ANEEL. Os dados do salário mínimo foram retirados do site do Instituto de Pesquisa Econômica Aplicada (IPEA) e são referentes ao salário mínimo real, que é o valor do salário mínimo nominal (o menor salário definido por lei para remuneração do trabalhador brasileiro), abatido o percentual de inflação do mês, o qual é medido através de diferentes índices de preço (IPEA, 2023).

Tabela 4 - Séries temporais de Consumo, Consumidores, Consumo Médio, Tarifa e Salário mínimo no estado do Ceará entre os anos de 2012 e 2021


Data	Consumo (KWh)	Consumidores	Consumo Médio (KWh)	Tarifa (R\$/KWh)	Salário Mínimo (R\$)
01/01/2012	104094	1130932	92,04	383,12	1218,20
01/02/2012	99150	1154325	85,89	383,12	1213,47
01/03/2012	101341	1163907	87,07	383,12	1211,29
01/04/2012	107845	1165328	92,54	372,69	1203,58
01/05/2012	102859	1177462	87,36	348,36	1197,00
01/06/2012	107725	1183227	91,04	348,36	1193,90
01/07/2012	105631	1191930	88,62	348,36	1188,79
01/08/2012	108184	1195132	90,52	348,36	1183,46
01/09/2012	107628	1200298	89,67	348,36	1176,05
01/10/2012	112073	1201395	93,29	348,36	1167,76
01/11/2012	112318	1205618	93,16	348,36	1161,49
01/12/2012	114238	1210221	94,39	348,36	1152,96

Fonte: EPE, ANEEL e IPEA

A utilização de outras séries temporais tem como objetivo relacioná-las com o Consumo Médio, a fim de verificar se seriam capazes de explicar o comportamento de uma, baseada na influência da outra. Tudo isso, com o auxílio dos modelos de previsão, que foram gerados em algoritmo, executado na linguagem de programação Python na versão 3.10.12, na nuvem, através da plataforma Google Colab. O gráfico 6 ilustra a série temporal da coluna Consumo Médio da tabela 4, a qual se quer fazer a previsão.



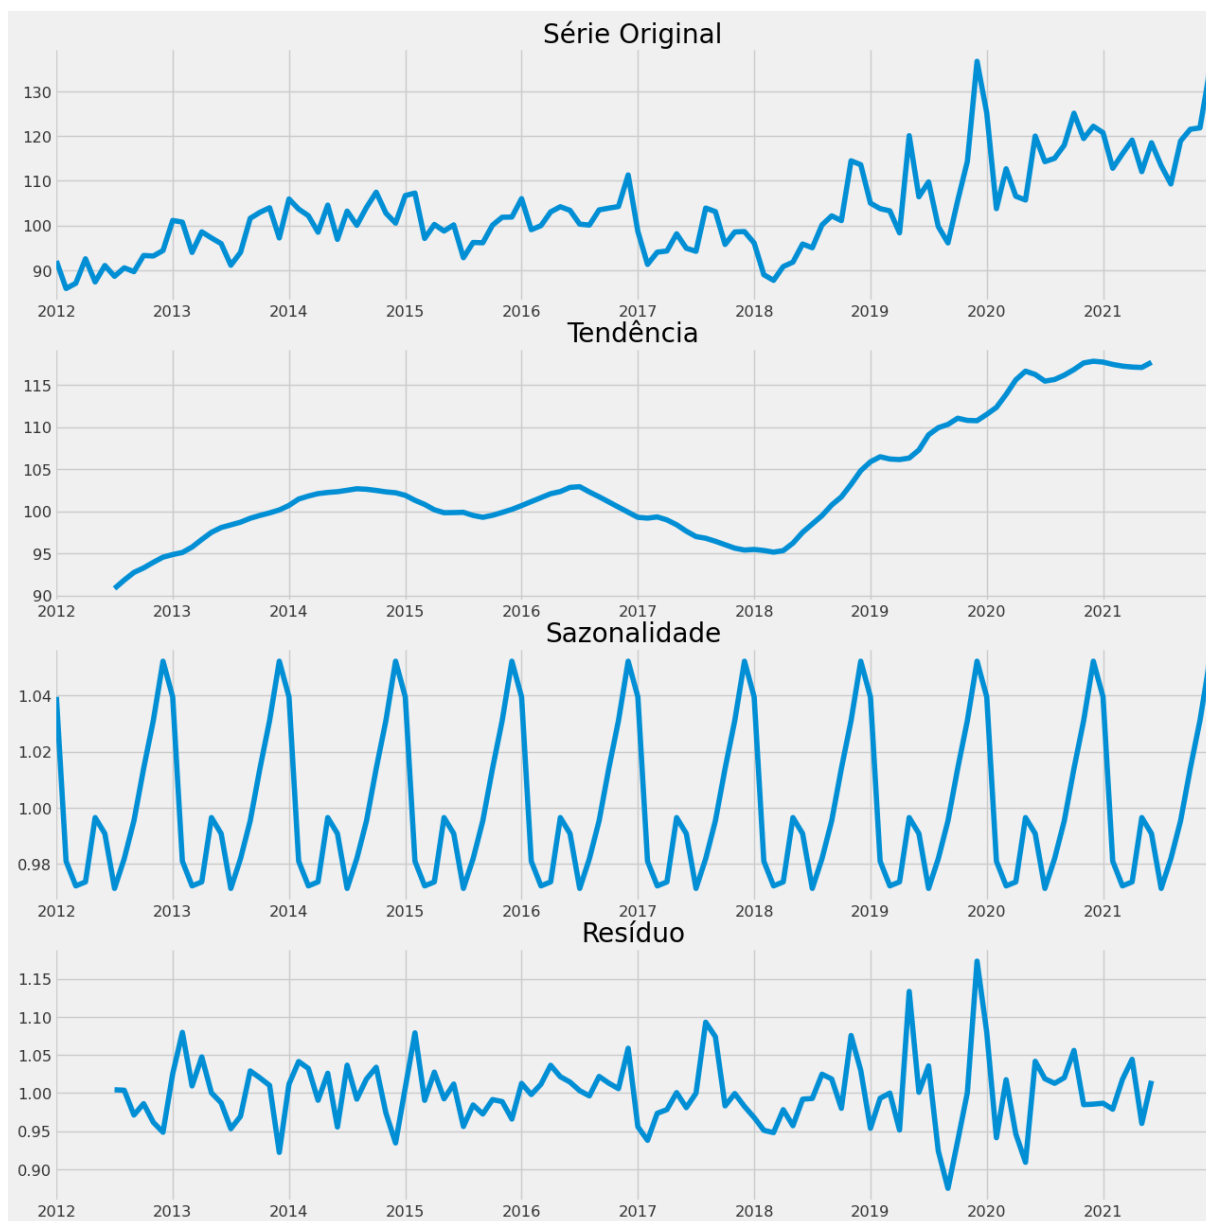
Gráfico 6 - Consumo de energia elétrica do consumidor baixa renda no Ceará 2012-2021



Fonte: EPE (2023).

A sua decomposição para extrair as componentes tendência, sazonalidade e ruído é mostrada no gráfico 7.


Gráfico 7 - Decomposição da série temporal do consumo de energia elétrica do consumidor baixa renda no Ceará 2012-2021



Fonte: EPE (2023).

É possível notar que a tendência varia nessa série, podendo apresentar tendência de crescimento em alguns períodos, e em outros, apresentar decréscimo. Também pode ser visto a repetição de padrões em determinados meses dos anos, ilustrando a sua componente sazonal. O gráfico 8 é o da função de autocorrelação da série temporal do consumo médio, que tem como finalidade ajudar a detectar se a série é ou não estacionária visualmente.


Gráfico 8 - Função de autocorrelação da série temporal do consumo de energia elétrica do consumidor baixa renda no Ceará 2012-2021



Fonte: EPE (2023).

Devido ao decréscimo lento das *lags* no gráfico é possível apontar que a série não é estacionária. Entretanto, para detectar a estacionariedade da série temporal em análise, de maneira mais assertiva, foram feitos os testes de raiz unitária de Dickey-Fuller Aumentado (ADF) e o de KPSS, utilizando a biblioteca Statsmodels da linguagem Python, comprovando que a série não é estacionária. O gráfico 9 mostra a matriz de correlação entre as variáveis das séries temporais analisadas.

Gráfico 9 - Matriz de correlação entre as variáveis analisadas



Fonte: EPE, ANEEL e IPEA.

Quanto mais azul maior será o grau de correlação positiva entre as duas grandezas, que significa que quando uma aumentar a outra também irá aumentar. Por outro lado, quanto mais verde, maior será o grau de correlação negativa entre as variáveis, significando que, quando uma aumentar a outra irá diminuir. A matriz de correlação entre as variáveis analisadas é importante, pois no modelo SARIMAX é utilizada uma variável exógena para explicar a sua interferência na previsão da série temporal de consumo médio.

## 4.2 Modelagens preditivas

### 4.2.1 Suavização exponencial

O modelo de suavização exponencial utilizado foi o de Holt-Winters (HW) com o método aditivo. Para isso, foi empregada a biblioteca *Darts* da linguagem Python, que contém ferramentas possíveis de executar o modelo de suavização exponencial de Holt-Winters apenas ajustando alguns parâmetros (PYTHON SOFTWARE FOUNDATION, 2023).

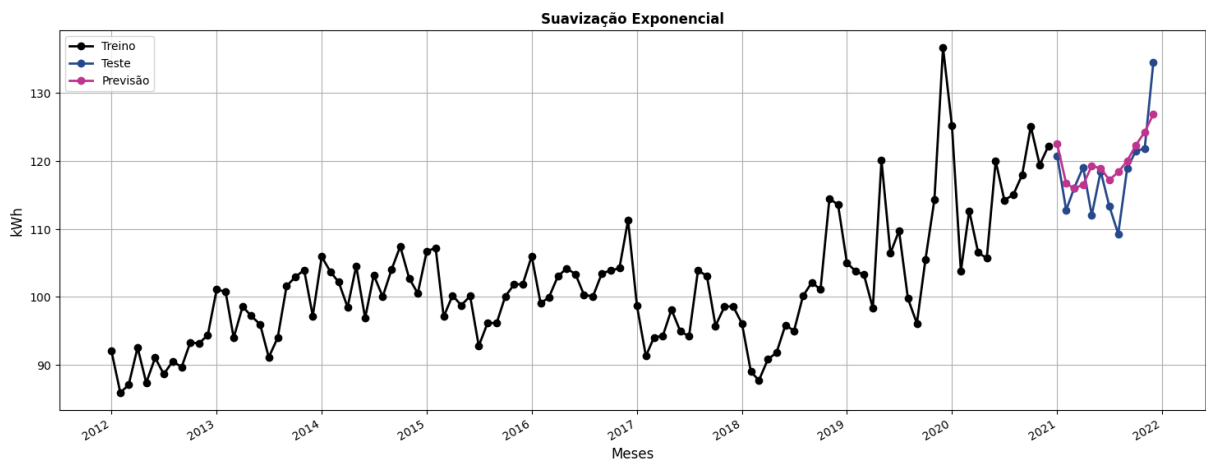
O conjunto de dados foram separados em dados de treino e teste com o método *train, test = ts\_suav.split\_before(pd.Timestamp('2021-01-01'))*, sendo que os dados de treino correspondem às observações do período de janeiro de 2012 até dezembro de 2020 (108 meses).

Os dados de teste são as observações feitas de janeiro de 2021 à dezembro de 2021 (12 meses), os quais serão utilizados para validar o modelo, comparando os valores reais com os

valores previsto. Após a separação em dados de treino e teste, o modelo é treinado pelo método  $model\_suav.fit(train)$  e a previsão é realizada por  $predict\_suav = model\_suav.predict(len(test))$ .

O gráfico 10 mostra uma comparação da previsão (rosa) com os dados reais (azul), junto com os dados de treino em preto, do modelo de Suavização Exponencial.

Gráfico 10 - Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo de Suavização Exponencial



Fonte: Elaborado pelo autor com base em dados da EPE.

O erro absoluto percentual médio (MAPE) entre os valores previstos e os valores reais (teste) no modelo de suavização exponencial foi de 2,91%, conforme a tabela 5 mostra.

Tabela 5 - Erro absoluto percentual médio (MAPE) no modelo de suavização exponencial

<b>SUAVIZAÇÃO EXPONENCIAL</b>			
<b>Data</b>	<b>Consumo Médio Valor Real (KWh)</b>	<b>Consumo Médio Valor Previsto (KWh)</b>	<b>ERRO (%)</b>
01/01/2021	120,74	122,49	1,45
01/02/2021	112,78	116,68	3,46
01/03/2021	116,03	115,97	0,05
01/04/2021	119,09	116,51	2,17
01/05/2021	112,03	119,28	6,47
01/06/2021	118,49	118,92	0,36
01/07/2021	113,36	117,22	3,41
01/08/2021	109,28	118,37	8,32
01/09/2021	118,88	120	0,94
01/10/2021	121,51	122,31	0,66
01/11/2021	121,83	124,27	2,00
01/12/2021	134,49	126,9	5,64
<b>MAPE</b>			<b>2,91</b>

Fonte: Elaborado pelo autor com base em dados da EPE.


#### 4.2.2 ARIMA

A previsão realizada com o modelo ARIMA foi feita com o uso da biblioteca PMDARIMA da linguagem Python, utilizando a função `Auto_Arima()`, uma ferramenta que automatiza os processos de escolha de parâmetros  $p$ ,  $P$ ,  $d$ ,  $D$ ,  $q$  e  $Q$  para a execução da metodologia de Box-Jenkins. Primeiramente, os valores desses parâmetros serão inicializados a critério do usuário e, em seguida, a função `Auto_Arima()` irá fazer as combinações desses parâmetros e gerará os AIC (*Akaike's Information Criterion*), selecionando, assim, o modelo de menor AIC, ressaltando que, quanto menor os AIC, melhor é o modelo ajustado, conforme o conjunto de dados.

A função `Auto_Arima()` foi definida inicialmente por: `stepwise_model = auto_arima(df['Consumo Médio'], start_p=1, start_q=1, start_d= 1, start_P=0, max_p=6, max_q=6, m=12, seasonal=True, trace=True, stepwise=False)`. Onde foi escolhida a coluna Consumo Médio `df['Consumo Médio']` do conjunto de dados para ser feita a previsão; os parâmetros  $p$ ,  $P$ ,  $d$ ,  $D$ ,  $q$  e  $Q$  foram inicializados, sendo que ( $p$ ,  $d$ ,  $q$ ) componentes não-sazonais e ( $P$ ,  $D$ ,  $Q$ ) componentes sazonais; e o parâmetro `seasonal` foi inicializado como `True`, o que significa que esse é um modelo SARIMA e tem uma componente sazonal. A função obteve como melhor modelo selecionado o SARIMA (1,1,1) (1,0,1), o qual obteve um AIC de 759,38.

O gráfico 11 mostra uma comparação da previsão (rosa) com os dados reais (azul) junto com os dados de treino em preto do modelo ARIMA.

Gráfico 11 - Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo ARIMA



Fonte: Elaborado pelo autor com base em dados da EPE.

O erro absoluto percentual médio (MAPE) entre os valores previstos e os valores reais (teste) no modelo ARIMA foi de 3,40%, conforme a tabela 6 mostra.

Tabela 6 - Erro absoluto percentual médio (MAPE) no modelo ARIMA

<b>ARIMA</b>			
<b>Data</b>	<b>Consumo Médio Valor Real (KWh)</b>	<b>Consumo Médio Valor Previsto (KWh)</b>	<b>ERRO (%)</b>
01/01/2021	120,74	120,15	0,49
01/02/2021	112,78	116,63	3,41
01/03/2021	116,03	118,13	1,81
01/04/2021	119,09	117,23	1,57
01/05/2021	112,03	119,21	6,40
01/06/2021	118,49	120,54	1,73
01/07/2021	113,36	120,02	5,88
01/08/2021	109,28	119,99	9,80
01/09/2021	118,88	120,48	1,34
01/10/2021	121,51	122,34	0,69
01/11/2021	121,83	123,03	0,99
01/12/2021	134,49	125,47	6,71
<b>MAPE</b>			<b>3,40</b>

Fonte: Elaborado pelo autor com base em dados da EPE

#### 4.2.3 SARIMAX

A previsão realizada com o modelo SARIMAX teve como ferramenta também a linguagem de programação Python na plataforma de computação em nuvem do Google Colab. A biblioteca da linguagem Python utilizada foi o Statsmodels, que possui a função que automatiza o processo de previsão do modelo SARIMAX, o qual só é necessário ajustar os parâmetros iniciais e a variável exógena que irá servir como uma grandeza que ajudará a explicar a predição da série temporal de consumo médio.

As variáveis exógenas (explicativas) são duas: salário mínimo e tarifa, sendo que são feitas simulações separadas, primeiro fazendo a previsão da série temporal de consumo médio, considerando a influência do salário mínimo e, em seguida, outra simulação para prever o consumo médio, baseado na influência da tarifa.


Primeiro, os dados foram separados em de treino e de teste e, após isso, foi aplicado o modelo SARIMAX, através da função: `model_srx = SARIMAX(train_sar['Consumo Médio'], order = (1, 1, 1), seasonal_order = (1, 1, 1, 12), exog = train_sar['Salário Mínimo'])`. Onde

$train\_sar['Consumo\ Médio']$  corresponde a série temporal do consumo médio com os dados de treinamento,  $order = (1, 1, 1)$  e  $seasonal\_order = (1, 1, 1, 12)$  são os parâmetros da parte autorregressiva, de médias móveis e de diferenciações das componentes sazonais e não sazonais e  $exog = train\_sar['Salário\ Mínimo']$  é a série temporal de treinamento da variável exógena.

O modelo foi treinado através do método  $train\_srx = model\_srx.fit()$  e, em seguida, foram feitas as previsões através de outro método  $predict\_srx = train\_srx.get\_forecast(steps = 12, exog = test\_sar['Salário\ Mínimo']).predicted\_mean$ . Quando a variável exógena utilizada foi a tarifa, a coluna salário mínimo da tabela do conjunto de dados analisados foi substituída pela das tarifas.

O gráfico 12 mostra uma comparação da previsão (rosa) com os dados reais (azul), junto com os dados de treino em preto do modelo SARIMAX com variável exógena salário mínimo.

Gráfico 12 - Comparação dos valores reais de demanda de energia elétrica com os valores previstos no modelo SARIMAX com variável exógena salário mínimo



Fonte: Elaborado pelo autor com base em dados da EPE.

O erro absoluto percentual médio (MAPE) entre os valores previstos e os valores reais (teste) nessa ocasião foi de 2,99%, conforme a tabela 7.




Tabela 7 - Erro absoluto percentual médio (MAPE) no modelo SARIMAX com variável exógena salário mínimo

<b>SARIMAX_SALÁRIO</b>			
<b>Data</b>	<b>Consumo Médio Valor Real (KWh)</b>	<b>Consumo Médio Valor Previsto (KWh)</b>	<b>ERRO (%)</b>
01/01/2021	120,74	119,261	1,23
01/02/2021	112,78	111,630	1,02
01/03/2021	116,03	113,000	2,61
01/04/2021	119,09	111,168	6,66
01/05/2021	112,03	117,620	4,99
01/06/2021	118,49	116,958	1,29
01/07/2021	113,36	115,440	1,84
01/08/2021	109,28	114,429	4,71
01/09/2021	118,88	114,299	3,86
01/10/2021	121,51	117,644	3,18
01/11/2021	121,83	121,427	0,33
01/12/2021	134,49	128,861	4,18
<b>MAPE</b>			<b>2,99</b>

Fonte: Elaborado pelo autor com base em dados da EPE.

O gráfico 13 mostra uma comparação da previsão (rosa) com os dados reais (azul), junto com os dados de treino em preto, do modelo SARIMAX com variável exógena tarifa.

Gráfico 13 - Comparação dos valores reais de demanda de energia elétrica com os valores previsto no modelo SARIMAX com variável exógena tarifa



Fonte: Elaborado pelo autor com base em dados da EPE.

O erro absoluto percentual médio (MAPE) entre os valores previstos e os valores reais

(teste) nessa ocasião foi de 2,58%, conforme a tabela 8 mostra.

Tabela 8 - Erro absoluto percentual médio (MAPE) no modelo SARIMAX com variável exógena tarifa

<b>SARIMAX_TARIFA</b>			
<b>Data</b>	<b>Consumo Médio Valor Real (KWh)</b>	<b>Consumo Médio Valor Previsto (KWh)</b>	<b>ERRO (%)</b>
01/01/2021	120,74	119,677	0,88
01/02/2021	112,78	112,427	0,31
01/03/2021	116,03	114,250	1,53
01/04/2021	119,09	112,254	5,74
01/05/2021	112,03	118,542	5,81
01/06/2021	118,49	118,183	0,26
01/07/2021	113,36	117,170	3,36
01/08/2021	109,28	116,610	6,71
01/09/2021	118,88	117,037	1,55
01/10/2021	121,51	120,830	0,56
01/11/2021	121,83	124,712	2,37
01/12/2021	134,49	131,982	1,86
<b>MAPE</b>			<b>2,58</b>

Fonte: Elaborado pelo autor com base em dados da EPE.

## 5 CONCLUSÃO

Fazer uma previsão de demanda de energia elétrica com uma boa precisão é componente fundamental para o planejamento energético no setor elétrico, isso porque auxilia as concessionárias de energia a saberem o perfil da carga dos consumidores que estão em sua área de concessão. Ao saber como essa carga se comporta, é possível traçar novos investimentos na rede de distribuição e alocar recursos financeiros de maneira eficiente sem que haja grandes perdas.

Quando há um conhecimento de quanto cada classe de consumo irá precisar de energia para realizar as suas funções, em um determinado horizonte de tempo, a sua compra nos leilões organizados pela ANEEL acontece de forma mais eficiente e sustentável, sem que as concessionárias tenham grandes perdas financeiras e aloquem os seus recursos em áreas de maneira estratégica.

Os modelos preditivos abordados nessa dissertação apresentaram resultados bastante satisfatórios, como erros variando entre 2 a 4%. No modelo de suavização exponencial, o erro foi de 2,91%, apresentando o segundo menor MAPE. O modelo ARIMA, que obteve o melhor desempenho, foi o SARIMA (1,1,1) (1,0,1) com um erro de 3,40%, tendo o menor MAPE entre os modelos analisados.

Quanto ao modelo SARIMAX, que utiliza uma variável exógena no processo de previsão, apresentou o melhor desempenho entre os métodos estudados quando a variável explicativa utilizada foi a tarifa, apresentando um MAPE de 2,58%. Quando a variável exógena foi o salário-mínimo, o modelo também apresentou um bom desempenho, porém, um pouco abaixo de quando utilizada a tarifa, com um MAPE de 2,99%. Isso revela o quanto diferentes grandezas têm um certo impacto na análise de outras, desta forma, conclui-se que o impacto das tarifas no orçamento familiar desta subclasse de consumidores tem maior relevância que o aumento do salário-mínimo no período observado.

Todos os modelos de previsão de demanda utilizados conseguiram identificar bem os padrões sazonais e de tendência em relação aos dados reais, o que revela que se ajustaram bem ao conjunto de dados analisados.

### 5.1 Trabalhos Futuros

A sugestão de trabalhos futuros desenvolvidos a partir dessa dissertação são:

- Previsão de demanda das classes de consumo utilizando métodos de inteligência

artificial;

- Análise da participação das concessionárias nos leilões de energia no ACR;
- Modelos de previsão da demanda para o dia seguinte;
- Modelagem e previsão de geração fotovoltaica utilizando modelos híbridos.
- Previsão de séries temporais da velocidade dos ventos como subsídio nos estudos da geração eólica.

## REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Resolução Normativa - estabelece as regras de prestação do serviço público de distribuição de energia elétrica. Nº 1.000, 07 dez. 2021.** Diário Oficial. Disponível em: <<https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-1.000-de-7-de-dezembro-de-2021-368359651>>. Acesso em: 18 maio 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Resolução Normativa - estabelece os procedimentos de distribuição de energia elétrica no sistema elétrico nacional. Nº 956, 07 dez. 2021.** Diário Oficial. Disponível em: <<https://www2.aneel.gov.br/cedoc/ren2021956.html>>. Acesso em: 19 maio 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Resolução Normativa - estabelece os direitos e deveres do consumidor de energia elétrica. Nº 1.000, 07 dez. 2021.** Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/noticias/2022/conheca-a-resolucao-1-000-que-reune-os-direitos-e-deveres-do-consumidor-de-energia-eletrica>>. Acesso em: 18 maio 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Resolução Normativa - procedimentos de distribuição de energia elétrica no sistema elétrico nacional. Nº 1, 07 dez. 2021.** Diário Oficial. Disponível em: <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>>. Acesso em: 19 maio 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Tarifa social.** Brasília, DF, 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/tarifas/tarifa-social>>. Acesso em: 18 maio 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Base de dados das tarifas das distribuidoras de energia elétrica.** Brasília, DF, 2023. Disponível em: <<https://portalrelatorios.aneel.gov.br/luznatarifa/basestarifas>>. Acesso em: 11 mar. 2023.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). **Tarifa social de energia elétrica.** Brasília, DF, 2023. Disponível em: <[https://www2.aneel.gov.br/aplicacoes\\_liferay/relatorios\\_de\\_qualidade\\_v2/](https://www2.aneel.gov.br/aplicacoes_liferay/relatorios_de_qualidade_v2/)>. Acesso em: 11 mar. 2023.

AMARAL, Mariane; SILVEIRA, Anderson; MATTOS, Viviane; BORGES, Eduardo. Previsão da demanda de energia elétrica a curto prazo para Região Sul do Brasil utilizando o Modelo ARIMA e o Modelo de Suavização Exponencial de Holt (SEH). *In*: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL (ENIAC), 17, 2020, Evento Online. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2020. p. 495-506. ISSN 2763-9061. DOI: <https://doi.org/10.5753/eniac.2020.12154>. Acesso em: 11 mar. 2023.

ARAÚJO, E. G. et al. **Modelagem e previsão de modelos de séries temporais do consumo de energia elétrica na Região Nordeste do Brasil.** Sigmae: Alfenas-MG, p.10-28, 2023.

ASSOCIAÇÃO BRASILEIRA DOS COMERCIALIZADORES DE ENERGIA. **Diferenças entre consumidores livres e cativos.** Disponível em: <<https://abraceel.com.br/mercado-livre/diferencas-entre-consumidores-livres-e-cativos/>>. Acesso em: 18 maio 2023.

BARROS, A. C. et al. **Análise de séries temporais em R: curso introdutório**. 1ª. ed. Rio de Janeiro: Elsevier, 2018.

BUENO, R. D. L. D. S. **Econometria de séries temporais**. 2. ed. São Paulo: Cengage Learning Brasil, 2018.

CÂMARA DE CORMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Adesão**. Disponível em: <<https://www.ccee.org.br/web/guest/mercado/adesao>>. Acesso em: 18 maio 2023.

DAIMON ENGENHARIA E SISTEMAS. **Relatório técnico de caracterização da carga para levantamento das curvas típicas do 4º ciclo de revisão tarifária**. Fortaleza: Enel, 2018.

ELSARAITI, M. et al. Time Series Analysis of Electricity Consumption Forecasting Using ARIMA Model. **2021 IEEE Green Technologies Conference (GreenTech)**, Denver, CO, USA, 2021. 259-262.

EMPRESA DE PESQUISA ENERGÉTICA. **Anuário estatístico de energia elétrica**. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>. Acesso em: 18 maio 2023.

EMPRESA DE PESQUISA ENERGÉTICA. **Boletim trimestral de consumo de eletricidade**. Brasília, 2023. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/boletim-trimestral-de-consumo-de-eletricidade>>. Acesso em: 23 ago. 2023.

EMPRESA DE PESQUISA ENERGÉTICA. **Planejamento energético**. Brasília, 2023. Disponível em: <<https://www.epe.gov.br/pt/areas-de-atuacao/planejamento-energetico>>. Acesso em: 19 maio 2023.

EMPRESA DE PESQUISA ENERGÉTICA - EPE. **Plano nacional de energia elétrica 2050**. Brasília, 2023. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-nacional-de-energia-pne>>. Acesso em: 15 ago. 2023.

EMPRESA DE PESQUISA ENERGÉTICA. **Publicações**. Brasília, 2023. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes>>. Acesso em: 20 jun. 2023.

HYNDMAN, R. J.; ATHANASOPOULOS, G. Forecasting: principles and practice. *In: FORECASTING: principles and practice*, 3. ed - OTexts: Melbourne, Australia, 2021. Disponível em: <<https://otexts.com/fpp3/>>. Acesso em: 25 maio 2023.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA. Ipea Data. **Instituto de Pesquisa Econômica Aplicada**, Brasília, 2023. Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>>. Acesso em: 10 abr. 2023.

MOOKE, D. S.; NOTZ, W. I.; FLINGER, M. A. **A estatística básica e sua prática**. 7. ed. Rio de Janeiro: LTC, 2017.

MORETTIN, P. A. **Econometria Financeira: um curso em séries temporais financeiras**. 3. ed. São Paulo: Editora Blucher, 2017.

MORETTIN, P. A.; TOLÓI, C. M. C. **Análise de séries temporais: modelos lineares univariados**. 3. ed. São Paulo: Editora Blucher, v. 1, 2018.

NAFIL, A. et al. Comparative study of forecasting methods for energy demand in Morocco. **Energy reports**, Atenas, p. 523-536, 2020.

NOUREEN, S. et al. Analysis and application of seasonal ARIMA model in energy demand forecasting: a case study of small scale agricultural load. **2019 IEEE 62nd International Midwest Symposium on Circuits and Systems**, Dallas: TX, USA, p. 521-524, 2019.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO (Brasil). **Boletim da copa do mundo: Brasil x Bélgica** - 06 jul 1918, às 15h, 2018. Disponível em: <<http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/Boletim%20da%20Copa%20do%20Mundo%20-%20Brasil%20x%20Belgica%20-%20060718%20%C3%A0s%2015h00.pdf>>. Acesso em: 19 maio 2023.

PYTHON SOFTWARE FOUNDATION. Welcome to python.org. **Documentation**, 2023. Disponível em: <<https://www.python.org/doc/>>. Acesso em: 09 abr. 2023.

ROSSI, J. W.; NEVES, C. D. **Econometria e séries temporais com aplicações à dados da economia brasileira**. Rio de Janeiro: LTC, 2014.

SOUSA, A. R. D. S. et al. **Análise de séries temporais**. Porto Alegre: Sagah Educação S.A, 2021.

VELASQUEZ, C. E. et al. Analysis of time series models for Brazilian electricity demand forecasting. **Energy**, Belo Horizonte, 15 fev. 2022.

WELCOME to colabatory - Google Research, 2023. Disponível em: <[https://colab.research.google.com/?utm\\_source=scs-index](https://colab.research.google.com/?utm_source=scs-index)>. Acesso em: 16 mar. 2023.

**ANEXO**



**ANEXO – CÓDIGO EM PYTHON**

```
#Import packages

import pandas as pd

import numpy as np

import scipy as sc

import math

import seaborn as sns

import matplotlib.pyplot as plt

import matplotlib.pylab as plt

sns.set_style()

import sklearn

from matplotlib.pylab import rcParams

rcParams['figure.figsize'] = 12, 6

plt.rcParams["figure.figsize"] = 12, 6

import warnings

import datetime as dt

import statsmodels as sm

from statsmodels.tsa.seasonal import seasonal_decompose

from statsmodels.tsa.stattools import adfuller, kpss

from scipy.stats import shapiro, kstest, normaltest

from statsmodels.graphics.tsaplots import plot_acf, plot_pacf

from pathlib import Path

from darts.metrics import mape, mae, mse, r2_score, rmse

from sklearn.metrics import mean_squared_error, mean_absolute_error,
mean_absolute_percentage_error, r2_score

from statsmodels.tools.eval_measures import rmspe, rmse
```

```
from sklearn.metrics import mean_absolute_percentage_error as mape

from darts.models import *

from darts import TimeSeries

from tbats import BATS, TBATS

from statsmodels.tsa.statespace.sarimax import SARIMAX

from statsmodels.tsa.arima.model import ARIMA

from sklearn.preprocessing import MinMaxScaler

plt.style.use("fivethirtyeight")

from pmdarima.arima import auto_arima

%matplotlib inline

pip install tbats

pip install darts

pip install pmdarima

df = pd.read_excel("dataset_energia_2.xlsx")
Consumo = df["Consumo"]
Data = df["Data"]
Consumo_Médio = df["Consumo Médio"]
df['Data'] = pd.to_datetime(df['Data'], format = '%d/%m/%Y')
df.index = pd.to_datetime(df['Data'], format = '%d/%m/%Y')
df.drop('Data', inplace=True, axis=1)
df.head(12)
df.shape
df.columns
df.info()

df.isnull().sum()
df.describe()
df["Consumo Médio"].describe()
sns.histplot(data = df, x = "Consumo Médio", kde = True)
```

```

df.corr()
#plt.figure(figsize=(14,7))
sns.heatmap(df.corr(), annot = True, cmap = "crest", fmt=".2f");
rcParams['figure.figsize'] = 10, 5
plt.rcParams["figure.figsize"] = 10, 5
sns.scatterplot(data = df, x= "Tarifa", y= "Consumo Médio")
#ACF e PACF série Consumo
plot_acf(df['Consumo Médio'], alpha = 0.05, lags = 12, title = 'Autocorrelation')
plot_pacf(df['Consumo Médio'], alpha = 0.05, lags = 12, title = 'Partial Autocorrelation')
plt.show();
#Function test Stationary série Consumo Médio
def print_results(output, test = 'adf'):
    pval = output[1]
    test_score = output[0]
    lags = output[2]
    decision = 'Non-Stationary'
    if test == 'adf':
        critical = output[4]
        if pval < 0.05:
            decision = 'Stationary'
        elif test=='kpss':
            critical = output[3]
            if pval >= 0.05:
                decision = 'Stationary'
        output_dict = {
            'Test Statistic': test_score,
            'P-value': pval,
            'Numbers of lags': lags,
            'Decision': decision
        }
    for key, Consumo_Médio in critical.items():
        output_dict["Critical Value (%s)" % key] = Consumo_Médio
    return pd.Series(output_dict, name = test)
#Applying tests

```

```

adf_output = adfuller(df['Consumo Médio'])
kpss_output = kpss(df['Consumo Médio'])
#Print Results
pd.concat([print_results(adf_output, 'adf'),
print_results(kpss_output, 'kpss')],
axis=1)
plt.figure(figsize=(14,7))
plt.plot(Data,Consumo_Médio)
plt.xlabel('Ano', fontsize=18)
plt.ylabel('Consumo (kW)', fontsize=18)
plt.title("Historico de Consumo por Mês no Ceará", fontsize=25)
plt.legend()
plt.show();
#result = seasonal_decompose(df)
decomp_serie = seasonal_decompose(df['Consumo Médio'], model='multiplicative')
fig, (ax1, ax2, ax3, ax4) = plt.subplots(4,1, figsize=(14,15))
decomp_serie.observed.plot(ax = ax1, title = 'Original Serie', xlabel = "")
decomp_serie.trend.plot(ax = ax2, title = 'Trend', xlabel = "")
decomp_serie.seasonal.plot(ax = ax3, title = 'Seasonal', xlabel = "")
decomp_serie.resid.plot(ax = ax4, title = 'Residual', xlabel = "")
plt.show();
stepwise_model = auto_arima(df['Consumo Médio'], start_p=1,start_q=1,start_d= 1, start_P=0,
max_p=6, max_q=6, m=12, seasonal=True, trace=
print(stepwise_model.aic())
train = df.loc['2012-01-01':'2020-12-01']
test = df.loc['2021-01-01':'2021-12-01']
display(test['Consumo Médio'])
#display(test['Consumidores'])
#display(test)
display(train['Consumo Médio'])
stepwise_model.fit(train['Consumo Médio'])
future_forecast = stepwise_model.predict(n_periods=12)
future_forecast
# Comparing Forecast vs Real Values (Train/Test)

```

```

fig, ax = plt.subplots(figsize=(18,6))
train['Consumo Médio'].plot(label = 'Train', marker ='o', color = 'Black')
test['Consumo Médio'].plot(label = 'Test', marker ='o', color = '#27498C')
future_forecast.plot(label = 'Predict', marker ='o', color = '#BF348E')
plt.ylabel('kW',size = 12)
plt.xlabel('Meses',size = 12)
plt.title('ARIMA',size = 12, weight = "bold")
plt.style.use('default')
plt.grid()
plt.show();
#Setting Time Series Object
ts_suav = TimeSeries.from_dataframe(df.reset_index(),
time_col = 'Data',
value_cols = 'Consumo Médio',
freq = 'MS')
#Separate Train and Test
train, test = ts_suav.split_before(pd.Timestamp('2021-01-01'))
#Applying Model
model_suav = ExponentialSmoothing(seasonal_periods = 12)
#Training Model
model_suav.fit(train)
#Forecasting
predict_suav = model_suav.predict(len(test))
predict_suav
# Comparing Forecast vs Real Values (Train/Test)
fig, ax = plt.subplots(figsize=(18,6))
train.plot(label = 'Train', marker ='o', color = 'Black')
test.plot(label = 'Test', marker ='o', color = '#27498C')
predict_suav.plot(label = 'Predict', marker ='o', color = '#BF348E')
plt.ylabel('kW',size = 12)
plt.xlabel('Meses',size = 12)
plt.title('Exponential Smoothing',size = 12, weight = "bold")
plt.style.use('default')
plt.grid()

```

```
plt.show();
#Separate Train and Tes
train_sar = df[:'2020-12-01']
test_sar = df['2021-01-01':]
#Applying SARIMAX
model_srx = SARIMAX(train_sar['Consumo Médio'],
order = (1, 1, 1),
seasonal_order = (1, 1, 1, 12),
exog = train_sar['Tarifa'])
#Training Model
train_srx = model_srx.fit()
#Forecasting
predict_srx = train_srx.get_forecast(steps = 12, exog = test_sar['Tarifa']).predicted_mean
#Transforming forecasting in DataFrame
predict_srx = pd.DataFrame(predict_srx)
test_sar['Consumo Médio']
predict_srx
#Comparing Forecast vs Real Values
pd.concat([train_sar['Consumo Médio'], test_sar['Consumo Médio'], predict_srx], axis =
1).plot(linewidth = 1, figsize = (18,6), marker =
plt.ylabel('kW',size = 12)
plt.xlabel('Meses', size = 12)
plt.title('SARIMAX',size = 15, weight = "bold")
plt.legend(['Train','Test', 'Predict'], loc = 'upper left')
plt.style.use('default')
plt.grid()
plt.show()
```