

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

GABRIEL STENGHELE

**PREVISÃO DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE: UM
ESTUDO DE CASO USANDO SARIMA**

MEDIANEIRA

2021

GABRIEL STENGHELE

**PREVISÃO DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE: UM
ESTUDO DE CASO USANDO SARIMA**

**Electricity consumption forecasting in the southeastern region: a case study
using sarima models**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica da Universidade
Tecnológica Federal do Paraná (UTFPR).

Orientador: Jose Ailton Azevedo dos Santos.

Coorientador: Leandro Antonio Pasa.

MEDIANEIRA

2021



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

GABRIEL STENGHELE

**PREVISÃO DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO
SUDESTE: UM ESTUDO DE CASO USANDO SARIMA**

Trabalho de conclusão de Curso apresentado à disciplina de Trabalho de Conclusão de Curso 2 (TCC 2) do Curso de Engenharia Elétrica, da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica

Data de aprovação: 27 de abril de 2021

José Airton Azevedo dos Santos. Dr
Universidade Tecnológica Federal do Paraná

Leandro Antônio Pasa. Dr
Universidade Tecnológica Federal do Paraná

Carlos Aparecido Fernandes. Dr
Universidade Tecnológica Federal do Paraná

Evandro André Konopatzki. Dr
Universidade Tecnológica Federal do Paraná

A Folha de Aprovação assinada encontra-se na coordenação do Curso.

RESUMO

O presente trabalho propõe a implementação de um modelo computacional para previsão do consumo de energia elétrica da região sudeste do Brasil, utilizando modelos estocásticos do Grupo SARIMA (Autorregressivo Integrado de Média Móvel com a característica Sazonal da série). Foi utilizada uma série com consumo de energia elétrica mensal dos anos de 2004 a 2018. Como critério de escolha do modelo foi utilizado a raiz do erro quadrático médio, o erro médio absoluto, o critério Akaiake e o U-Theil. O modelo escolhido foi o SARIMA(1,1,1)(2,1,3). Os resultados obtidos, deste modelo, demonstram sua eficácia para um horizonte de curto prazo.

Palavras-chave: SARIMA. Consumo de Eletricidade. Energia Elétrica. Previsão.

ABSTRACT

The present work proposes the implementation of a computational model to forecast the electric power consumption of southeastern Brazil, using stochastic models of the SARIMA Group (Integrated Moving Average Autoregressive with the Seasonal Characteristic of the series). A series with the monthly electricity consumption from 2004 to 2018 was used in this work. The criterion for choosing the model was the root mean square error, the absolute mean error, the Akaiake criterion and the U-Theil. The chosen model was the SARIMA (1,1,1) (2,1,3). The results obtained from this model demonstrate its effectiveness for a short term horizon.

Keywords: SARIMA. Electricity consumption. Electrical Energy. Prediction.

LISTA DE FIGURAS

FIGURA 1: CONSUMO DE ENERGIA ELÉTRICA NO PAÍS DE 2014 A 2018.	14
FIGURA 2: VARIAÇÃO NO CONSUMO DE ENERGIA ELÉTRICA NO PAÍS, ENTRE OS ANOS DE 2005 E 2018.	15
FIGURA 3: SÉRIE TEMPORAL DO CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE.	18
FIGURA 4: INTERFACE DO GRETL.	19
FIGURA 5: METODOLOGIA BOX-JENKINS.	20
FIGURA 6: SÉRIE ORIGINAL - REGIÃO SUDESTE	25
FIGURA 7: ANÁLISE DESCRITIVA DOS DADOS DE CONSUMO DE ENERGIA ELÉTRICA ENTRE 2004 E 2018 NA REGIÃO SUDESTE.	25
FIGURA 8: BOXPLOT DA SÉRIE TEMPORAL DO CONSUMO DA REGIÃO SUDESTE.	26
FIGURA 9: PERIODOGRAMA DOS DADOS DA REGIÃO SUDESTE.	27
FIGURA 10: PERIODOGRAMA DOS DADOS DA REGIÃO SUDESTE COM DEFASAGEM SAZONAL.	27
FIGURA 11: TESTE DE DICKEY FULLER APLICADO NA SÉRIE DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE.	28
FIGURA 12: TESTE DE DICKEY FULLER PARA UMA DIFERENCIAÇÃO SAZONAL DA SÉRIE DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE.	29
FIGURA 13: PRIMEIRA DIFERENCIAÇÃO NA SÉRIE DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE.	29
FIGURA 14: TESTE DE DICKEY FULLER DA PRIMEIRA DIFERENCIAÇÃO APLICADA À SÉRIE DE CONSUMO DE ENERGIA ELÉTRICA NA REGIÃO SUDESTE.	30
FIGURA 15: FUNÇÃO DE AUTOCORRELAÇÃO PARA PARAMETRIZAÇÃO DO MODELO SARIMA.	31
FIGURA 16: FUNÇÃO DE AUTOCORRELAÇÃO DOS RESÍDUOS DA SÉRIE ORIGINAL.	32
FIGURA 17: TESTE DE NORMALIDADE DOOMIK-HASSEN.	33
FIGURA 18: DADOS DE CONSUMO DE ENERGIA ELÉTRICA PREDITOS EM FUNÇÃO DO CONSUMO OBSERVADO.	33
FIGURA 19: SÉRIES: VALORES OBSERVADOS, VALORES PREDITOS E RESÍDUOS.	34
FIGURA 20: CONSUMO DE ENERGIA NA REGIÃO SUDESTE: VALORES OBSERVADOS E PREDITOS DE 2019.	35

LISTA DE TABELAS

TABELA 1: RANKING DAS DEZ NAÇÕES QUE MAIS CONSOMEM ENERGIA ELÉTRICA NO MUNDO (TWH)	15
TABELA 2: CONSUMO DOS SISTEMAS REGIONAIS DO PAÍS, COM ÊNFASE PARA AS REGIÕES SUL E CENTRO-OESTE (GWH).....	16
TABELA 3: CONSUMO DE ENERGIA ELÉTRICA POR CLASSE NO PAÍS (GWH).	16
TABELA 4: CAPACIDADE INSTALADA DE GERAÇÃO ELÉTRICA NO BRASIL ENTRE OS ANOS 2013 E 2017 (MW).....	17
TABELA 5: GERAÇÃO ELÉTRICA NO BRASIL NO PERÍODO DE 2013 A 2017 (GWH).	17
TABELA 6: RESULTADOS PARA CADA MODELO, ESPECIFICANDO AS MÉTRICAS.....	32
TABELA 7: RESULTADOS DA PREVISÃO.	35

LISTA DE ABREVIações E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
AR	Autoregressivo
ARMA	Autoregressive Moving Average (Médias Móveis Autoregressivas)
ARIMA	<i>Autoregressive Integrated Moving Average</i> (Autoregressivo Integrado de Médias Móveis)
BEN	Balanco energético nacional
EPE	Empresa de Pesquisa Energética
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
GWh	Gigawatt hora
MA	<i>Moving Average</i> (Médias Móveis)
MME	Ministério de Minas e Energia
MWh	Megawatt hora
ONS	Operador Nacional do Sistema Elétrico
PIB	Produto Interno Bruto
SARIMA	<i>Sazonal Autoregressive Integrated Moving Average</i> (Autoregressivo Integrado de Médias Móveis Sazonal)
SEP	Autoregressivo integrado de médias móveis sazonal

SUMÁRIO

1	INTRODUÇÃO	8
1.1	OBJETIVO GERAL	9
1.2	OBJETIVOS ESPECÍFICOS.....	9
1.3	JUSTIFICATIVA.....	10
2	REFERENCIAL TEÓRICO	11
2.1	SETOR ELÉTRICO BRASILEIRO	11
2.2	UM HISTÓRICO DE CONSUMO DE ENERGIA ELÉTRICA NO PAÍS.....	13
2.3	SÉRIES TEMPORAIS.....	17
2.4	O SOFTWARE.....	19
2.5	A METODOLOGIA BOX-JENKINS	20
2.6	O MODELO ARIMA	20
2.7	MÉTRICAS	23
3	METODOLOGIA.....	24
3.1	OBJETO DE ESTUDO.....	24
3.2	A SÉRIE.....	24
3.3	PARAMETRIZAÇÃO DA SÉRIE.....	25
4	RESULTADOS E DISCUSSÕES	32
4.1	VALIDAÇÃO DA MELHOR PARAMETRIZAÇÃO OBTIDA.....	34
5	CONCLUSÕES	36
6	REFERÊNCIAS BIBLIOGRÁFICAS	37

1 INTRODUÇÃO

Atualmente, o consumo de energia elétrica tem um papel importante na produção de diversos setores da economia. A energia elétrica é primordial, tanto para o funcionamento de computadores quanto para a transformação de matéria-prima em produtos acabados. É considerada como um dos indicadores do nível de qualidade de vida e do desenvolvimento econômico (KHEIRKHAH et al., 2013).

As empresas brasileiras que produzem matérias-primas nos setores petroquímicos, mineração, papel e celulose, metalúrgicos, siderúrgicos entre outros utilizam muita energia elétrica, podendo chegar, em alguns casos, até 30% do seu orçamento (JUNIOR, 2018). A previsão do consumo de energia elétrica consiste de um fator importante para tomada de decisão e orientações políticas futuras, por prever tendências, sazonalidades e ciclos futuros (JUNIOR, 2018). Técnicas para identificação de modelos de previsão são utilizadas na análise de séries temporais. As séries temporais são um conjunto de observações de uma variável, ordenado segundo o parâmetro tempo, geralmente em intervalos equidistantes. Os dados coletados podem ser diários, semanais, mensais, etc (MORETTIN, 2008).

Segundo Bressan (2004), as técnicas de previsão auxiliam na tomada de decisões em atividades que precisam de planejamento e avaliação constante, além de propiciarem a redução de incerteza por parte dos elos envolvidos numa determinada área de interesse.

A previsão de carga dos sistemas de energia elétrica é uma tarefa fundamental na geração, transmissão e distribuição. Qualquer gargalo que ocorra na produção, transmissão ou distribuição de energia elétrica pode acarretar na diminuição da produtividade das empresas. Por isso, estudos atrelados à previsão do consumo de energia elétrica podem ajudar na produtividade das empresas e evitar perdas de produção e de transporte (OLIVEIRA, 2004).

Um dos objetivos principais de uma empresa de energia elétrica é oferecer um serviço de alta qualidade a seus consumidores, garantindo-lhes uma tarifa razoável a partir da melhor gestão da rede elétrica de distribuição (TODESCO et al., 2004).

O trabalho está organizado da seguinte maneira. Na seção 2 apresenta-se a revisão de literatura realizada neste trabalho. Na Seção 3 é descrita a metodologia que deve ser empregada na previsão do consumo de energia elétrica da região

sudeste. Na Seção 4 são apresentados os resultados obtidos da aplicação da metodologia em questão, por meio do software GRET, em observações mensais do consumo de energia elétrica da região sudeste. Comentários finais e conclusões, na Seção 5, finalizam o trabalho.

1.1 OBJETIVO GERAL

Este trabalho descreve e modela a série temporal de médias mensais do consumo de energia elétrica, da região sudeste do Brasil, utilizando modelos estocásticos do Grupo SARIMA (Autorregressivo Integrado de Média Móvel com a Característica Sazonal da Série).

1.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos, descritos abaixo, são propostos para que o objetivo geral possa ser alcançado.

- a) Estimar os parâmetros do modelo ajustado.
- b) Efetuar a escolha do modelo SARIMA mais adequado.
- c) Testar e validar o modelo.

1.3 JUSTIFICATIVA

O estudo de previsão de demanda, por meio de séries temporais, consiste na utilização de dados passados e presentes para se obter dados futuros através de modelos estatísticos. A previsão de demanda é uma atividade de grande importância para as empresas de energia, tanto para distribuidoras que necessitam programar suas compras a curto, médio e longo prazo, quanto para as geradoras que necessitam antecipar-se aos leilões no mercado de energia. Portanto, a sobrevivência destas empresas depende de compreender e mensurar, de maneira correta, a demanda de energia elétrica. Pois a eletricidade, em grandes quantidades, ainda não pode ser armazenada de forma viável e eficiente. Segundo Unsuhay et al. (2010) tanto a superestimação quanto a subestimação da geração de energia elétrica geram custos e devem ser evitadas. Portanto, um eficiente planejamento sobre o comportamento da demanda de energia elétrica é indispensável para as empresas do setor, para a maximização de lucro e minimização de riscos.

2 REFERENCIAL TEÓRICO

Estudos de previsão de carga, entre outros motivos econômicos, são muito importantes para o planejamento da expansão do Sistema Elétrico de Potência (SEP). Este capítulo apresenta uma revisão bibliográfica, abordando estudos sobre análises de séries temporais, com enfoque no histórico de consumo de energia elétrica.

2.1 SETOR ELÉTRICO BRASILEIRO

O setor elétrico brasileiro começa a se desenvolver somente após o início do século XX, pois, até então, o país era sistematicamente voltado à produção agrária, conseqüentemente a participação da eletricidade tanto nos meios de produção quanto nas cidades, era inexpressiva. Somente após o desenvolvimento das cidades do Rio de Janeiro e São Paulo que os investimentos no setor elétrico, por meio de capital estrangeiro, tomam um considerável estímulo e com isso, as primeiras companhias de energia elétrica são instaladas. Com este fomento ao desenvolvimento elétrico, em 1920, com a economia voltada à industrialização, os números de usinas hidroelétricas começam a apresentar um crescimento significativo (ALBUQUERQUE, 2008).

Após a Segunda Guerra Mundial, os processos de urbanização se intensificam no Brasil juntamente com a industrialização, o crescimento da demanda de energia elétrica se torna inevitável e, por conta da falta de recursos energéticos à pronta entrega, se faz presente um custoso, porém necessário, período de racionamento de energia nos principais centros urbanos do país. Este, por sua vez, impulsiona os investimentos em infra estruturas maiores e mais robustas que as existentes até então (VEIGA e FONSECA, 2002).

Uma reorganização do sistema elétrico brasileiro começa a partir da década de 1950, com uma forte absorção das empresas privadas por estados da federação e, conseqüentemente, quase todos os estados brasileiros fundam suas próprias estatais. Em 1957 e 1961 nascem a central elétrica de Furnas, com o intuito de atender o sudeste do país e a hidrelétrica do Vale da Paraíba. Com o desenvolvimento acelerado dos centros urbanos, o consumo de energia elétrica aumenta e fomenta o

desenvolvimento e construção de mais usinas hidrelétricas no país (ALBUQUERQUE, 2008).

Entre as décadas de 60 e 80, o país já tinha a sua matriz energética bem definida sobre os alicerces da geração hidráulica e com o setor obtendo bons lucros e ganhos de produtividade. Tendo em vista o crescimento anual que era da ordem de 10%, os projetos de Tucuruí e Itaipu são executados, aumentando ainda mais os laços do país com a geração hidráulica (ALBUQUERQUE, 2008).

Após períodos de desestatização do setor elétrico, o sistema de planejamento e previsão fica desaparelhado e, conseqüentemente, leva o setor rumo a problemas que somente foram enfrentados entre as décadas de 1990 e 2000. A demanda por energia elétrica entre estes anos cresceu 49%, enquanto a capacidade de geração no país cresceu somente 33%. Fica evidente a perda de garantia no fornecimento de energia e um déficit na geração é concebido (VEIGA e FONSECA, 2002).

Os períodos sucessores à década de 90 modificaram o sistema elétrico brasileiro em dois aspectos muito fortes. O primeiro vem, juntamente com as privatizações das companhias operadoras do sistema elétrico, a partir de dezembro de 1996, com a Lei nº 9.427 que cria uma agência regulatória para o setor elétrico e determina o novo modelo de exploração dos meios hídricos do país. Este, por sua vez, trabalha com a concorrência entre as empresas e através de leilões, a fim de conseguir dos lances efetuados pelas empresas participantes das negociações, o maior valor pela outorga. Já no ano de 2004, o novo modelo do Setor Elétrico a ser introduzido traz novas características, com relação econômica, ao sistema. Doravante as proposições do sistema são: garantir segurança no suprimento; promover a modicidade tarifária e a inserção social. O grande marco desse modelo tem destaque no resgate da responsabilidade do planejamento do setor de energia elétrica pelo Estado (ANEEL, 2008).

A crise que resultou no apagão do ano de 2001, no setor elétrico, foi correspondente ao baixo nível dos reservatórios das hidrelétricas e também a falta de investimentos no setor. Após este apagão, novos planos de gestão e investimentos foram criados e implantados, assim obtendo algum avanço no setor. Porém no ano de 2014, devido a algumas falhas na área de investimentos e aplicações de projetos, houve uma nova crise energética e hídrica no país (BORBA, 2015).

As crises energéticas são muito impactantes na questão do desenvolvimento econômico de um país, onde estas limitam a capacidade de expansão dos produtos,

da renda e dos empregos (CARMINATI; SCALCO, 2013). Para explicar o desenvolvimento econômico, uma função de produção é utilizada e esta, por sua vez, é um processo que depende de insumos, onde entra a questão energética e impacta diretamente nos produtos finais. Uma correlação direta é criada entre o crescimento econômico de um país e o seu respectivo consumo de energia elétrica (GODINHO, 2015).

A relação entre o PIB e a quantidade de energia nos países desenvolvidos não é a mesma que nos países em desenvolvimento. Para países desenvolvidos, não são percebidos padrões que relacionam diretamente o crescimento destas duas variáveis. O processo de separação se dá pois, por um longo período, houve uma relação muito grande entre a energia e o PIB, explicado pelo processo de industrialização e crescimento do país, porém, neste ponto do percurso, todas as necessidades básicas da sociedade foram atendidas, assim o consumo de energia passa a crescer com uma relação de ligação mais afastada do PIB. Já no Brasil, devido a sua posição de país em desenvolvimento, as necessidades básicas da sociedade não foram devidamente atendidas e o processo de industrialização necessita se intensificar, com isso o consumo de energia tende a ocupar patamares elevados, juntamente com o PIB, demonstrando um padrão de comportamento uniforme (FRANCELINO; ARRAES, 2010).

Como uma parte significativa da produção de energia no Brasil é hidráulica, uma vulnerabilidade no setor é criada devido a possibilidade de uma estiagem severa atingir o país. Uma solução para este fenômeno seria a utilização de usinas termoelétricas, mesmo que uma de suas consequências seja o aumento temporário do custo da energia (GODINHO, 2015).

2.2 UM HISTÓRICO DE CONSUMO DE ENERGIA ELÉTRICA NO PAÍS

O consumo de energia elétrica está diretamente atrelado ao desenvolvimento de praticamente todos os setores produtivos do país e também ao bem-estar populacional, proporcionando e indicando um maior uso das tecnologias em geral. Este também é um forte indicador do ritmo das atividades industriais, comerciais e de serviços do país ou das regiões (ANEEL, 2008).

Em condições atuais, a EPE (Empresa de Pesquisa Energética) apresenta no Anuário Estatístico de Energia Elétrica 2018, dados relacionados ao consumo de energia elétrica na rede de distribuição dos últimos cinco anos, com ênfase no ano de 2017 (ano base).

No ano de 2017, uma retomada do crescimento no consumo de eletricidade no país é percebida, após dois anos de queda, com o aumento de 1,2% em relação a 2016, alcançando a faixa de 467 TWh e mantendo o Brasil entre os dez maiores consumidores de energia elétrica do mundo. A Figura 1 apresenta um escopo de consumo de energia elétrica no Brasil, nos anos de 2014 a 2018.

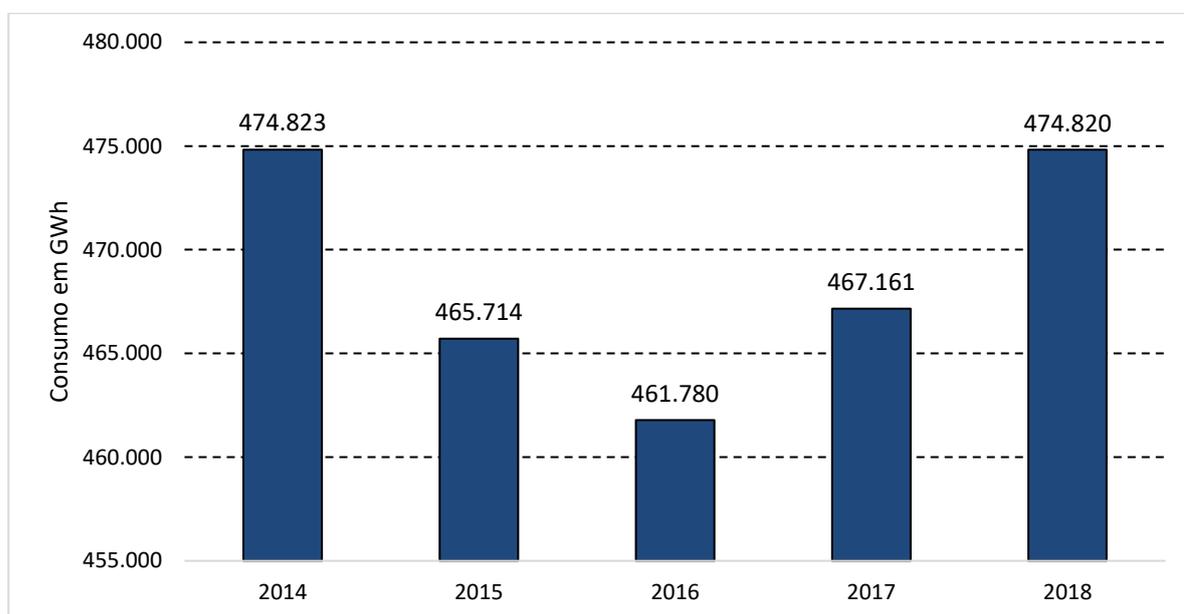


Figura 1: Consumo de energia elétrica no país de 2014 a 2018.
Fonte: (EPE; ANEEL, 2021).

Na Figura 2, apresenta-se a variação percentual anual do consumo de energia elétrica no Brasil, considerando o ano anterior de cada período como referência. Por meio desta figura, pode-se perceber uma ligeira queda no consumo de energia a partir do ano de 2010, atingindo o auge no ano de 2015, com um crescimento negativo de 1,92%, representando um período de dificuldade que o país enfrentou, tanto na esfera econômica quanto na social.

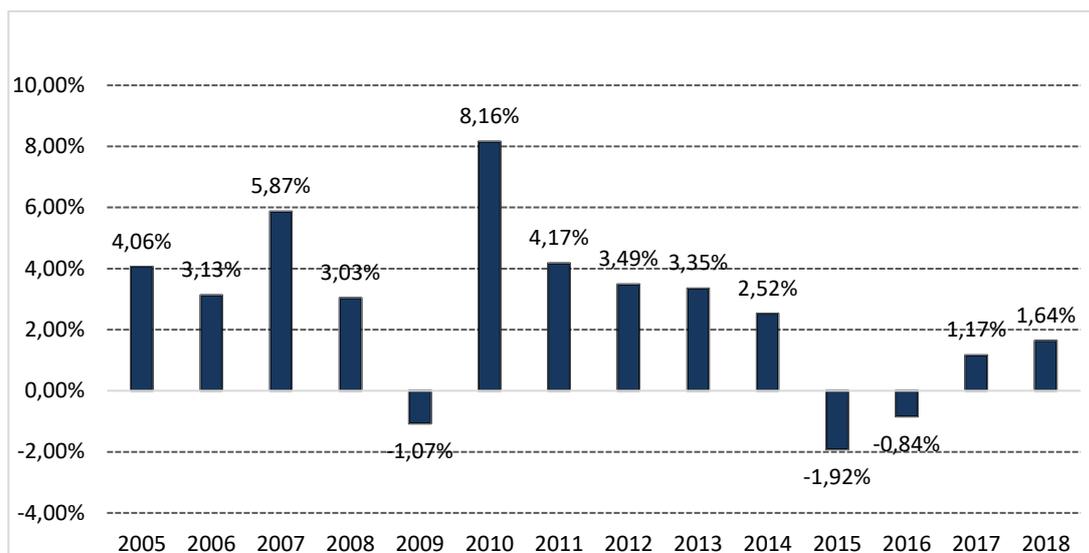


Figura 2: Variação no consumo de energia elétrica no país, entre os anos de 2005 e 2018.
Fonte: (EPE; ANEEL, 2021).

Na Tabela 1, é possível observar a estatística dos dez maiores consumidores de energia elétrica no mundo, com o Brasil ocupando a sétima posição no *ranking*.

	2011	2012	2013	2014	2015	Δ% (2014)	Part. % (2015)
Mundo	19.344,9	19.713,6	20.317,7	20.760,4	21.167,8	2,0	100,0
China	4.178,9	4.435,1	4.845,4	5.066,5	5.270,5	4,0	24,9
EUA	3.882,6	3.832,3	3.868,3	3.903,3	3.900,2	-0,1	18,4
Índia	802,3	845,7	897,6	973,1	1.053,7	8,3	5,0
Japão	1.029,5	957,0	960,1	952,4	933,7	-2,0	4,4
Rússia	874,8	889,1	881,1	891,1	890,2	-0,1	4,2
Alemanha	546,2	546,3	544,3	532,7	536,3	0,7	2,5
Brasil	481,0	498,4	516,2	532,6	524,6	-1,5	2,5
Canadá	525,9	519,0	538,5	541,1	520,5	-3,8	2,5
Coreia do Sul	472,7	482,8	487,8	495,0	498,1	0,6	2,4
França	443,5	455,1	455,0	432,6	440,1	1,7	2,1
Outros	6.107,5	6.252,7	6.323,5	6.440,1	6.600,0	2,5	31,2

Tabela 1: Ranking das dez nações que mais consomem energia elétrica no mundo (TWh)
Fonte: (EPE; ANEEL, 2021).

Os destaques de crescimento no consumo ficam para as Regiões Sul e Centro Oeste, com taxas de 3,1% e 2,4% (Tabela 2); porém, a Região Sudeste é a que apresenta maior consumo de energia elétrica no país, representando praticamente 50% do total. Do ponto de vista de classes consumidoras, o setor industrial dessa região é responsável por praticamente 36% do consumo total, assim como o setor residencial da mesma também possui valor elevado, com cerca de 29% (EPE; ANEEL, 2019).

	2013	2014	2015	2016	2017	$\Delta\%$ (2017/2016)	Part. % (2017)
Brasil	463.142	474.823	465.708	461.780	467.161	1,2	100,0
Norte	30.196	32.364	33.709	34.265	34.510	0,7	7,4
Nordeste	79.694	80.747	79.214	79.501	79.731	0,3	17,1
Sudeste	240.105	242.513	235.775	231.013	232.515	0,7	49,8
Sul	80.393	84.819	82.154	82.426	84.997	3,1	18,2
Centro-Oeste	32.755	34.381	34.855	34.574	35.408	2,4	7,6

Tabela 2: Consumo dos sistemas regionais do país, com ênfase para as regiões Sul e Centro-Oeste (GWh).

Fonte: (EPE; ANEEL, 2021).

Na Tabela 3, pode-se observar o consumo por classe do país, com sua linha de frente sendo o setor industrial, seguido pelo setor residencial. Como informado anteriormente, os números são de aproximadamente 36% e 29%, respectivamente.

	2013	2014	2015	2016	2017	$\Delta\%$ (2017/2016)	Part. % (2017)
Brasil	463.142	474.823	465.708	461.780	467.161	1,2	100
Residencial	124.908	132.302	131.190	132.872	134.368	1,1	28,8
Industrial	184.685	179.106	169.289	165.314	167.398	1,3	35,8
Comercial	83.704	89.840	90.768	87.873	88.292	0,5	18,9
Rural	23.455	25.671	25.899	27.266	28.136	3,2	6,0
Poder público	14.653	15.355	15.196	15.096	15.052	-0,3	3,2
Iluminação pública	13.512	14.043	15.333	15.035	15.443	2,7	3,3
Serviço público	14.847	15.242	14.730	14.969	15.196	1,5	3,3
Próprio	3.379	3.265	3.304	3.355	3.277	-2,3	0,7

Tabela 3: Consumo de energia elétrica por classe no país (GWh).

Fonte: (EPE; ANEEL, 2021).

Em termos de capacidade de geração, o Brasil apresentou uma expansão de 4,5% (Tabela 4), com uma predominância na energia hidráulica. O setor fotovoltaico foi o que obteve destaque, apresentando a maior expansão proporcional, com a cifra de quarenta vezes superior à do ano anterior.

Na área de geração, o crescimento foi de 1,6%, no período de 2016 a 2017, com grande destaque para as usinas eólicas, que representam aumento de 26,5%, e às gerações a gás natural, com 16,1%. A emissão de gases do efeito estufa caiu às cifras de 5,1% na geração elétrica do país e 4,9% no Sistema Interligado Nacional. Porém, a geração hidráulica apresentou uma pequena queda, sendo esta de 2,6%, no mesmo período.

A diminuição na geração por meio da queima de carvão mineral foi um dos fatores responsáveis pela diminuição dos gases do efeito estufa, mostrando que o país se importa tanto com a gestão energética quanto com os problemas ambientais; assim, o sistema brasileiro se torna cada vez mais comprometido com o meio ambiente e a sociedade.

	2013	2014	2015	2016	2017	$\Delta\%$ (2017/2016)	Part. % (2017)
Total	126.743	133.913	140.858	150.338	157.112	4,5	100,0
Usinas Hidrelétricas	81.132	84.095	86.366	91.499	94.662	3,5	60,3
Usinas Termelétricas	36.528	37.827	39.564	41.275	41.628	0,9	26,5
PCH	4.620	4.790	4.886	4.941	5.020	1,6	3,2
CGH	266	308	398	484	594	22,6	0,4
Usinas Nucleares	1.990	1.990	1.990	1.990	1.990	-	1,3
Usinas Eólicas	2.202	4.888	7.633	10.124	12.283	21,3	7,8
Solar	5	15	21	24	935	3.836,3	0,6

Tabela 4: Capacidade instalada de geração elétrica no Brasil entre os anos 2013 e 2017 (MW).
Fonte: (EPE; ANEEL, 2021).

Os dados referentes à geração de energia elétrica no país, correspondentes ao período de 2013 a 2017 são visíveis na Tabela 5.

	2013	2014	2015	2016	2017	$\Delta\%$ (2017/2016)
Total	570.835	590.542	581.228	578.898	587.962	1,6
Hidráulica (i)	390.992	373.439	359.743	380.911	370.906	-2,6
Gás Natural	69.003	81.073	79.490	56.485	65.593	16,1
Derivados de Petróleo (ii)	22.090	31.529	25.657	12.103	12.733	5,2
Carvão	14.801	18.385	18.856	17.001	16.257	-4,4
Nuclear	15.450	15.378	14.734	15.864	15.739	-0,8
Biomassa (iii)	39.679	44.987	47.394	49.236	49.385	0,3
Eólica	6.578	12.210	21.626	33.489	42.373	26,5
Outras (iv)	12.241	13.540	13.728	13.809	14.976	8,5

Tabela 5: Geração Elétrica no Brasil no período de 2013 a 2017 (GWh).
Fonte: (EPE, ANEEL, 2021).

2.3 SÉRIES TEMPORAIS

Uma série temporal (Figura 3) é basicamente um aglomerado de observações espaçadas por um intervalo de tempo (MORETTIN e TOLOI, 2006).

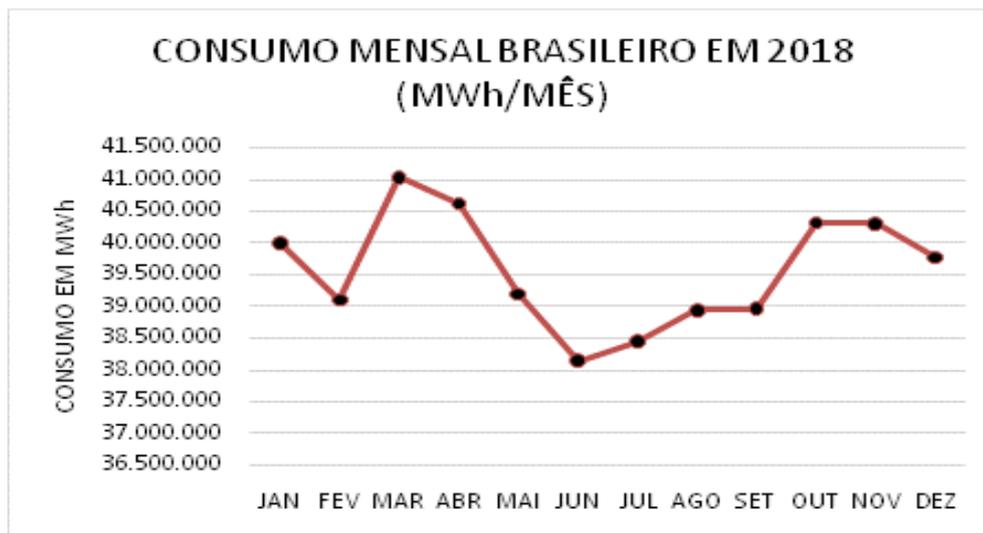


Figura 3: Série temporal do consumo de energia elétrica na região Sudeste.
Fonte: (EPE; ANEEL, 2021).

Modelos que são utilizados a fim de descrever séries temporais são denominados estocásticos, ou, em outras palavras, modelos controlados por leis probabilísticas.

A construção de modelos para descrever uma série temporal em particular depende de vários fatores, como o comportamento do fenômeno ou até mesmo o conhecimento antecipado sobre a sua natureza, ou ainda o objetivo da análise (GUJARATI; PORTER, 2011).

Conforme Rossi e Neves (2014), para que se possa escolher o modelo de previsão baseado em séries temporais, inicialmente deve-se conhecer o padrão de comportamento da série. A série poderá conter tendência, sazonalidade e variações irregulares.

O efeito da tendência em uma série temporal é definido como um comportamento dos dados que crescem e decrescem ao longo do tempo. O efeito sazonal refere-se às variações cíclicas que a série sofre. Movimento ondulatório de curta duração, em geral, inferior a um ano, associado em muitos dos casos a mudanças climáticas. Rossi e Neves (2014) definem variações irregulares como variáveis resultantes de causas não identificadas.

Dentre os modelos existentes no contexto de análise de séries temporais com dados econômicos ou sociais, onde os erros são auto correlacionados e se pretende estimar valores futuros, os modelos ARIMA são muito úteis (GUJARATI; PORTER, 2011).

2.4 O SOFTWARE

O software GRETL (Figura 4) é um pacote estatístico livre e multiplataforma desenvolvido principalmente para ser usado em pesquisas econométricas. Apresenta uma interface muito intuitiva e amigável, e permite a aplicação de uma ampla gama de técnicas econométricas de forma muito simples. Devido a facilidade de interação com a interface do programa, foi escolhido este software, dentre outros, para realizar a previsão do consumo de energia elétrica da Região Sudeste.

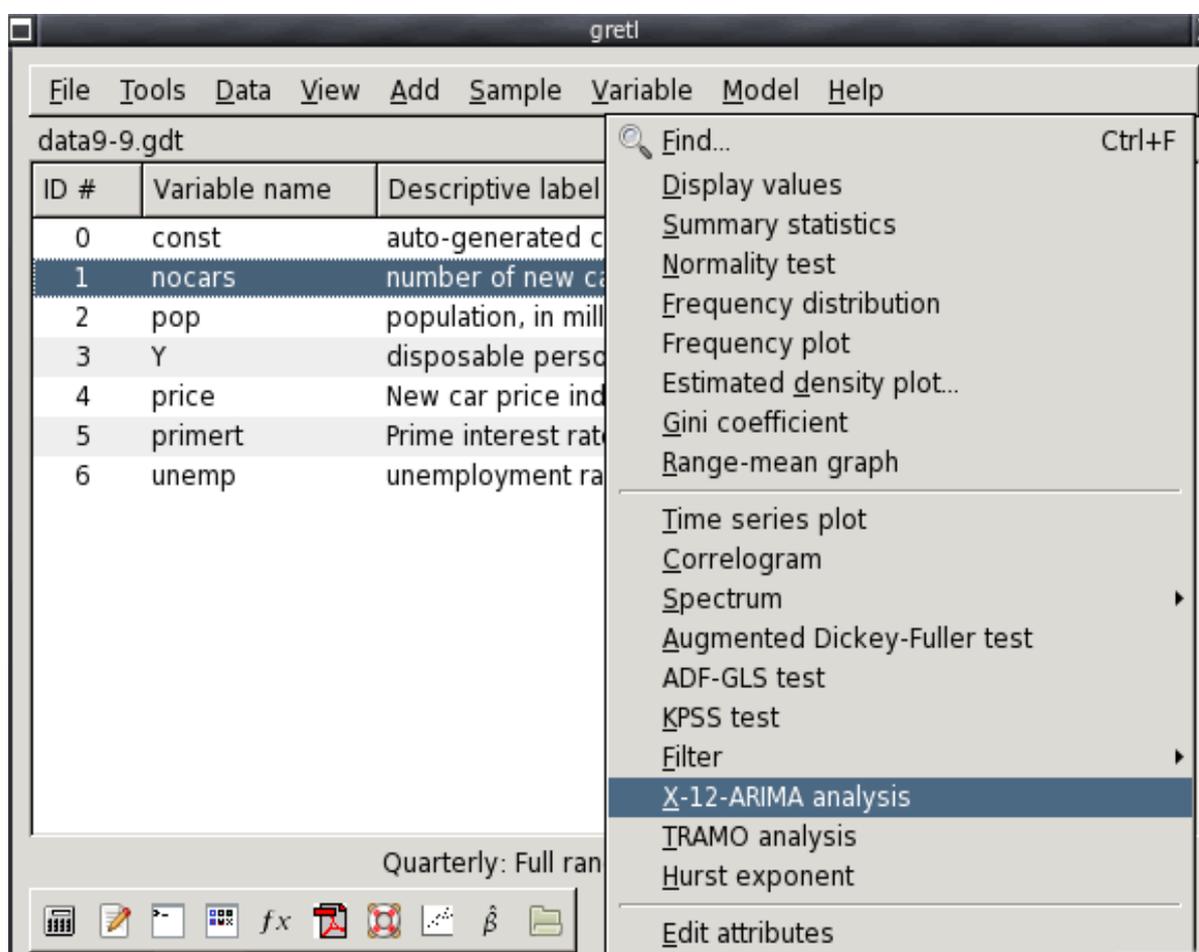


Figura 4: Interface do GRETL.
Fonte: O autor (2021).

O GRETL suporta vários estimadores estatísticos de mínimos quadrados, modelos de séries temporais e vários métodos de verossimilhança, além de conter o X-12-ARIMA, um pacote computacional para trabalhar com séries temporais.

2.5 A METODOLOGIA BOX-JENKINS

A metodologia *Box-Jenkins* é definida por três etapas iterativas: identificação do modelo, estimativa de parâmetros e diagnóstico (Figura 5). Esta metodologia inicia com a preparação dos dados. Na sequência, ocorre a seleção do modelo. Com o modelo selecionado estimam-se os parâmetros. Em seguida, a adequação do modelo é verificada. A previsão é o último passo desta metodologia (BOX; JENKINS, 1976).



Figura 5: Metodologia Box-Jenkins.
Fonte: O autor (2021)

2.6 O MODELO ARIMA

Segundo Matos (2000), esse modelo é utilizado, principalmente, para as previsões de curto prazo, sendo que uma desvantagem do uso desta metodologia é a

necessidade do conhecimento de programas computacionais para fazer a estimação dos modelos.

Para uma descrição dos modelos ARIMA é importante definir com maior precisão o que é estacionariedade e diferenciação, pois é necessário que uma série temporal seja estacionária para um bom ajuste desse modelo (MATOS, 2000).

Uma série temporal caracterizada como estacionária é aquela cujos comportamentos não dependem do tempo, ou seja, não apresentará padrões previsíveis ao longo do tempo. Dessa forma, uma série temporal com tendência ou sazonalidade não pode ser considerada estacionária (HYNDMAN; ATHANASOPOULOS, 2013).

A diferenciação consiste em transformar uma série não estacionária em uma série estacionária, estabilizando sua variância e sua média para remover alterações de nível, visando reduzir a tendência e a sazonalidade (HYNDMAN; ATHANASOPOULOS, 2013). Conforme Ehlers (2005), essa diferenciação pode ser feita por meio da diferença entre uma observação e sua observação anterior, como apresentado na Equação (1). Geralmente a aplicação de uma diferenciação é suficiente para torná-la estacionária.

$$Y'_t = Y_t - Y_{t-1} \quad (1)$$

Em que:

Y'_t = Valor diferenciado;

Y_t = Valor da série temporal do período t ;

t = índice do período.

Segundo Maddala (1992), um modelo autorregressivo é denotado por AR(p), dado pela Equação (2), que é similar à equação de regressão múltipla e, por isso, é chamada de regressivo. Entretanto, não é uma regressão baseada em variáveis independentes, mas em seus próprios valores passados e em seus erros aleatórios, sendo assim, denominado autorregressivo. Para uma série temporal estacionária, um modelo autorregressivo vê um valor de uma variável para o tempo “t” como uma função linear dos valores das “p” etapas de tempo que a precedem.

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t \quad (2)$$

Onde $Y_{t-1}, Y_{t-2} \dots Y_{t-p}$ são os valores das variáveis para períodos de tempos anteriores e ϵ_t é o erro aleatório no período "t". Os parâmetros da equação podem ser estimados por meio de softwares estatísticos.

Já os modelos de médias móveis, denominados MA(q) segundo Gujarati e Porter (2011), podem ser representados por meio da Equação (3). Para uma série temporal estacionária, um modelo de média móvel vê o valor de uma variável no tempo 't' como uma função linear de erros residuais das etapas de tempo 'q' que a precedem. O erro residual é calculado comparando o valor no momento 't' com a média móvel dos valores anteriores.

$$Y_t = \mu + \beta_0\epsilon_t + \beta_1\epsilon_{t-1} + \beta_2\epsilon_{t-2} + \dots + \beta_q\epsilon_{t-q} \quad (3)$$

em que μ é uma constante e $\epsilon_{t-1}, \epsilon_{t-2} \dots \epsilon_{t-q}$ são os termos dos erros para os períodos de tempos anteriores. Conforme Matos (2000), neste caso, os parâmetros são calculados por meio de métodos iterativos e complexos, que podem ser estimados com ajuda de softwares.

Já foi compreendido que, para uma série temporal estacionária, uma variável no tempo 't' é uma função linear de observações anteriores ou erros residuais. Portanto, ao combinar os dois, tem-se um modelo de média móvel auto regressiva (ARMA). No entanto, às vezes a série temporal não é estacionária, ou seja, as propriedades estatísticas de uma série, como a média e a variação, mudam ao longo do tempo. E os modelos estatísticos estudados até agora assumem que as séries temporais são estacionárias; portanto, pode-se incluir uma etapa de pré-processamento para diferenciar as séries temporais para torná-las estacionárias. Neste caso tem-se o modelo ARIMA (HYNDMAN; ATHANASOPOULOS, 2013):

$$ARIMA(p, d, q) \quad (4)$$

O modelo SARIMA é uma extensão do modelo ARIMA para lidar com dados sazonais. Simplificando, a metodologia SARIMA é a metodologia ARIMA aplicada duas vezes, na parte não sazonal e na parte sazonal. O Modelo SARIMA é representado por:

$$SARIMA(p, d, q)(P, D, Q) \quad (5)$$

Onde os parâmetros p , d e q são referentes à parte não sazonal da série e os parâmetros P , D e Q são referentes à parte sazonal. Os parâmetros p e P representam a ordem da auto regressão, d e D a ordem de diferenciação, e q e Q representam a ordem de média móvel no modelo (HYNDMAN; ATHANASOPOULOS, 2013).

2.7 MÉTRICAS

Existem vários indicadores de desempenho que são utilizados na avaliação da validade dos modelos de previsão e que são úteis também na comparação entre os modelos. Neste trabalho, os modelos devem ser avaliados pelos seguintes parâmetros:

- a) Raiz do Erro Quadrático Médio (RMSE): Raiz do erro médio quadrático da diferença entre a predição e o valor real.
- b) Erro Médio Absoluto (MAE): Como o RMSE, o MAE possui dimensão igual à dimensão dos valores observados e preditos. Seu valor representa o desvio médio entre observado e predito. Comparando o RMSE e o MAE, o primeiro dá um peso maior para desvios grandes (pois são elevados ao quadrado), enquanto o MAE dá um peso igual a todos os desvios.
- c) U de Theil: O coeficiente de U de Theil analisa a qualidade de uma previsão. O coeficiente menor que 1 indica uma previsão melhor do que a previsão ingênua. Quanto mais próximo ficar de zero, melhor será o resultado da previsão (SILVA, 2018).
- d) Critério de informação de Akaike (AIC): Este critério dá uma pontuação para o modelo de acordo com a sua adequação aos dados e na ordem do modelo, sendo que quanto menor o valor do critério de informação, melhor é o modelo (POLLI; VIEIRA, 2015).

3 METODOLOGIA

A metodologia utilizada neste estudo pode ser classificada quanto ao tipo de pesquisa, à população amostra, à coleta e à análise dos dados. A classificação quanto ao tipo de pesquisa pode ser subdividida: de acordo com a natureza, sendo esta aplicada; quanto aos objetivos, sendo descritiva; e quanto à forma de abordar o problema, sendo quantitativa, pois os dados obtidos no sistema real foram, em seguida, tratados estatisticamente.

Como estratégia de pesquisa, foi utilizado o estudo de caso que, conforme Yin (2013), é ideal em situações organizacionais reais em que o pesquisador não tem controle dos fenômenos.

3.1 OBJETO DE ESTUDO

Os dados utilizados na construção deste trabalho foram obtidos do relatório mensal do consumo de energia, fornecido pela Empresa de Pesquisa Energética – EPE.

A EPE é uma empresa pública, instituída nos termos da Lei nº 10.847, de 15 de março de 2004, e do Decreto nº 5.184, de 16 de agosto de 2004. Sua finalidade é prestar serviços na área de estudos e pesquisas destinados a subsidiar o planejamento do setor energético, tais como energia elétrica, petróleo e gás natural e seus derivados, carvão mineral, fontes energéticas renováveis e eficiência energética, dentre outras. A Lei nº 10.847, em seu Art. 4º, inciso II, estabelece entre as competências da EPE a de elaborar e publicar o Balanço Energético Nacional – BEN (EPE; ANEEL, 2019).

3.2 A SÉRIE

A série a ser analisada neste trabalho, apresentada na Figura 6, é constituída por observações mensais do consumo de energia elétrica na Região Sudeste do Brasil desde o dia 1 de janeiro de 2004 até o dia 31 de dezembro de 2018, num total de 180 observações.

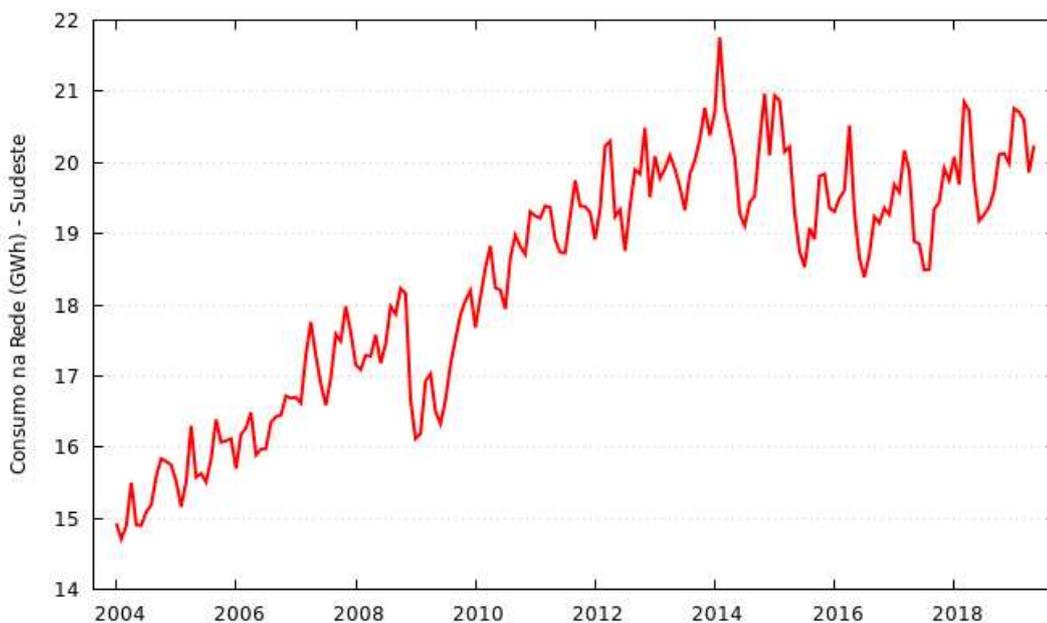


Figura 6: Série original - Região Sudeste
Fonte: Adaptado de ANEEL (2021).

3.3 PARAMETRIZAÇÃO DA SÉRIE

Inicialmente, realizou-se, por meio do software GRETl, uma análise descritiva dos dados da série temporal analisada neste trabalho (Figura 7).

```

Estatísticas descritivas, usando as observações 2004:01 - 2018:12
para a variável 'Sudeste' (180 observações válidas)

Média                18,316
Mediana              18,790
Mínimo               14,710
Máximo               20,970
Desvio padrão        1,6775
C.V.                  0,091586
Enviesamento         -0,44563
Curtose Ex.          -1,0032
percentil de 5%      15,501
percentil de 95%     20,691
Intervalo interquartil 2,8775
Obs. ausentes        0
  
```

Figura 7: Análise descritiva dos dados de consumo de energia elétrica entre 2004 e 2018 na Região Sudeste.
Fonte: O autor (2021).

Nota-se, dos dados apresentados na Figura 7, que a Região Sudeste teve um consumo mínimo, médio e máximo de 14,710, 18,316 e 20,970 GWh de energia da

rede elétrica. Sendo a região do Brasil que teve o maior consumo de energia durante o período analisado (2004 a 2018).

Observa-se também que o coeficiente de variação está muito bom (9,1%). Segundo Pimentel (2000), se o coeficiente de variação for inferior a 10% tem-se um coeficiente de variação baixo, de 10 a 20% médio, de 20 a 30% alto e acima de 30% muito alto.

Após realizar a análise exploratória, os dados foram plotados em forma de *boxplot* (Figura 8), para identificação de *outliers* (valores fora da normalidade).

As razões mais comuns para o surgimento de *outliers* são os erros na coleta de dados ou eventos raros e inesperados. Os *outliers* considerados como extremos só foram descartados da amostra depois de uma análise criteriosa de suas causas. Os valores julgados como possíveis de ocorrer foram mantidos na amostra.

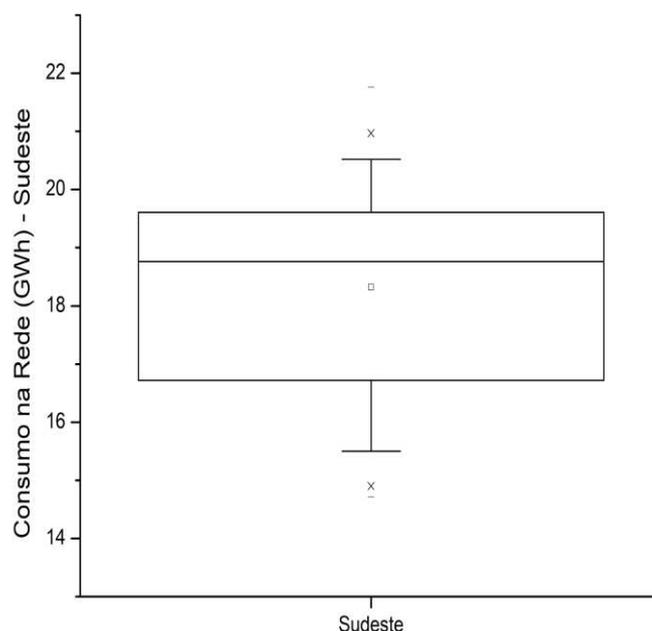


Figura 8: *Boxplot* da série temporal do consumo da Região Sudeste.
Fonte: O autor (2021).

Para identificar a presença de componentes sazonais foi analisado o periodograma da série (Figura 9).

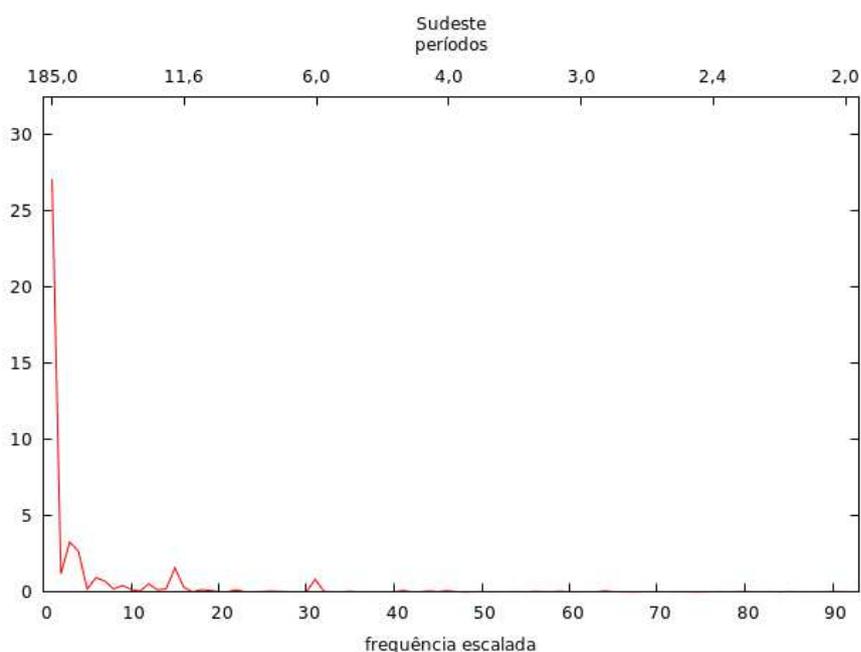


Figura 9: Periodograma dos dados da Região Sudeste.
Fonte: O autor (2021).

Pode-se observar, da Figura 9, que ocorreu um pico individualizado no periodograma, mostrando que existe, na série, um comportamento sazonal. Para modelar a sazonalidade na série, foi aplicada nos dados a diferença sazonal, tornando-a suavizada.

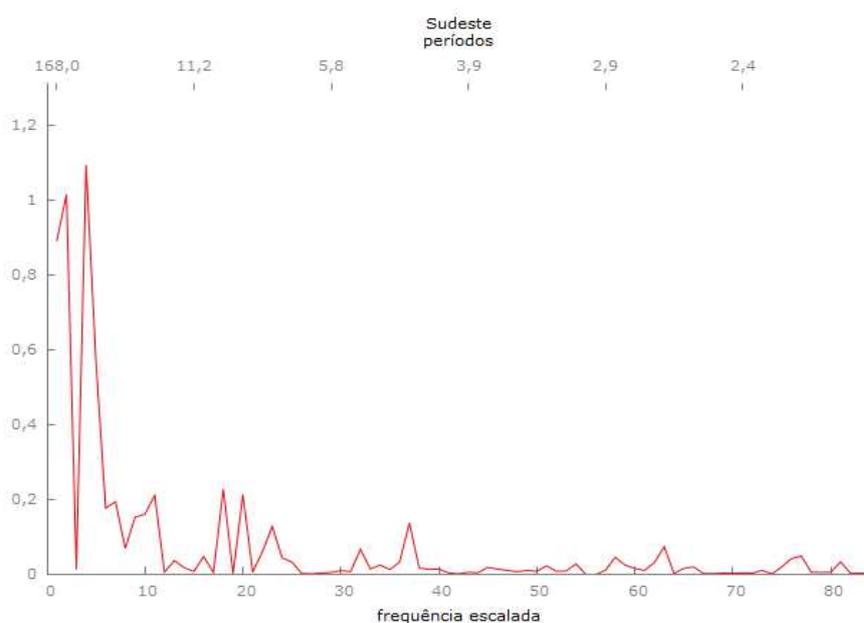


Figura 10: Periodograma dos dados da Região Sudeste com defasagem sazonal.
Fonte: O autor (2021).

Após a suavização da série, com uma defasagem sazonal, iniciou-se a análise da estacionariedade na amostra, pois percebe-se, pelo periodograma da Figura 10, que a sazonalidade já não é mais significativa como na série original. Com isto, o primeiro critério da parte sazonal é definido, sendo $D=1$, pois somente foi aplicada uma diferenciação sazonal.

A estacionariedade foi verificada pela análise da existência de raiz unitária na série original. Ao aplicar o teste ADF (Aumentado de Dickey-Fuller), observou-se que a hipótese nula H_0 (série possui raiz unitária – não estacionária) foi aceita, mostrando que a série possuía raiz unitária, sendo, portanto, não-estacionária. Isso ocorreu porque a série, conforme apresentado na Figura 11, apresentou p-valor assintótico maior que o nível de significância adotado (0,05).

```

Teste Aumentado de Dickey-Fuller para Sudeste
testar para baixo a partir de d 13efasagens, critério AIC
tamanho da amostra: 167
hipótese nula de raiz unitária: a = 1

teste sem constante
incluindo 12 defasagens de (1-L)Sudeste
modelo: (1-L)y = (a-1)*y(-1) + ... + e
valor estimado de (a - 1): 0,00299165
estatística de teste: tau_nc(1) = 1,70154
p-valor assintótico 0,979
coeficiente de 1ª ordem para e: -0,028
diferenças defasadas: F(12, 154) = 7,651 [0,0000]

teste com constante
incluindo 12 defasagens de (1-L)Sudeste
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0359226
estatística de teste: tau_c(1) = -1,7979
p-valor assintótico 0,382
coeficiente de 1ª ordem para e: -0,026
diferenças defasadas: F(12, 153) = 7,384 [0,0000]

com constante e tendência
incluindo 12 defasagens de (1-L)Sudeste
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0576232
estatística de teste: tau_ct(1) = -1,32671
p-valor assintótico 0,8811
coeficiente de 1ª ordem para e: -0,029
diferenças defasadas: F(12, 152) = 6,480 [0,0000]

```

Figura 11: Teste de Dickey Fuller aplicado na série de consumo de energia elétrica na região Sudeste.

Fonte: O autor (2021).

Um caminho natural para tornar a série estacionária é a diferenciação, ou seja, transformar a variável em sua primeira diferença. Aplicando uma diferenciação sazonal, temos então a série estacionária, como é possível verificar da Figura 12, com p-valor assintótico menor que o nível de significância adotado (0,05).

```

Teste Aumentado de Dickey-Fuller para sd_v2
testar para baixo a partir de 13 defasagens, critério AIC
tamanho da amostra: 155
hipótese nula de raiz unitária: a = 1

teste sem constante
incluindo 12 defasagens de (1-L)sd_v2
modelo: (1-L)y = (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,124543
estatística de teste: tau_nc(1) = -2,07658
p-valor assintótico 0,03634
coeficiente de 1ª ordem para e: 0,002
diferenças defasadas: F(12, 142) = 3,428 [0,0002]

teste com constante
incluindo 12 defasagens de (1-L)sd_v2
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,181161
estatística de teste: tau_c(1) = -2,51862
p-valor assintótico 0,111
coeficiente de 1ª ordem para e: 0,007
diferenças defasadas: F(12, 141) = 3,287 [0,0003]

com constante e tendência
incluindo 12 defasagens de (1-L)sd_v2
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,236216
estatística de teste: tau_ct(1) = -2,8638
p-valor assintótico 0,1745
coeficiente de 1ª ordem para e: 0,013
diferenças defasadas: F(12, 140) = 3,266 [0,0004]

```

Figura 12: Teste de Dickey Fuller para uma diferenciação sazonal da série de consumo de energia elétrica na região Sudeste.
Fonte: O autor (2021).

Na Figura 13, apresenta-se o gráfico da primeira diferença sazonal da série do consumo de energia.

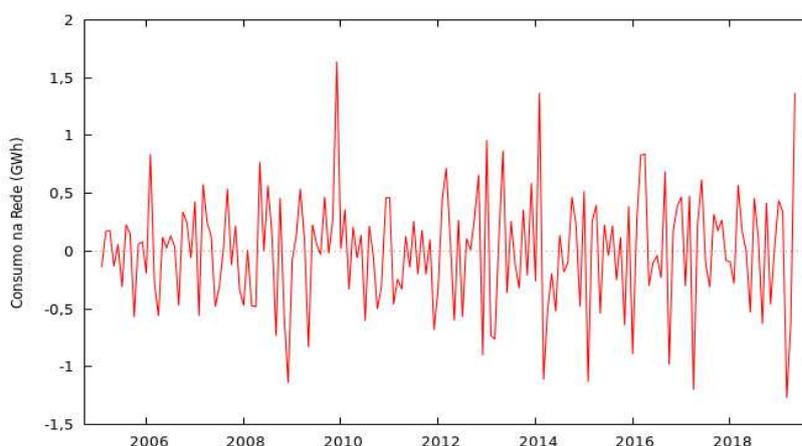


Figura 13: Primeira diferenciação na série de consumo de energia elétrica na Região Sudeste.
Fonte: O autor (2021).

Após a diferenciação sazonal validar a parametrização da componente (D) do modelo SARIMA, se faz necessário verificar a validação de uma diferenciação normal

para a componente não sazonal (d) do modelo SARIMA. Em geral, a primeira diferença de uma série é estacionária. Após a defasagem normal verificou-se, por meio do teste ADF, que a série se tornou estacionária (Figura 14), com base no p-valor assintótico menor que o nível de significância (0,05).

```

Teste Aumentado de Dickey-Fuller para d_Sudeste
testar para baixo a partir de d 13efasagens, critério AIC
tamanho da amostra: 167
hipótese nula de raiz unitária: a = 1

teste sem constante
incluindo 11 defasagens de (1-L)d_Sudeste
modelo: (1-L)y = (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -1,85924
estatística de teste: tau_nc(1) = -3,89808
p-valor assintótico 9,801e-05
coeficiente de 1ª ordem para e: -0,039
diferenças defasadas: F(11, 155) = 8,020 [0,0000]

teste com constante
incluindo 11 defasagens de (1-L)d_Sudeste
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -2,30285
estatística de teste: tau_c(1) = -4,34945
p-valor assintótico 0,0003592
coeficiente de 1ª ordem para e: -0,027
diferenças defasadas: F(11, 154) = 8,387 [0,0000]

com constante e tendência
incluindo 11 defasagens de (1-L)d_Sudeste
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -2,5249
estatística de teste: tau_ct(1) = -4,55803
p-valor assintótico 0,001161
coeficiente de 1ª ordem para e: -0,023
diferenças defasadas: F(11, 153) = 8,560 [0,0000]

```

Figura 14: Teste de Dickey Fuller da primeira diferenciação aplicada à série de consumo de energia elétrica na região Sudeste.

Fonte: O autor (2021).

Em resumo, para identificar o modelo SARIMA (p,d,q)(P,D,Q) faz-se necessário identificar os parâmetros p, d, q, P, D e Q. Como a série foi suavizada e se tornou estacionária com apenas uma diferenciação sazonal e normal, então tem-se d=D=1 e os parâmetros p, q, P e Q são obtidos por meio das funções de autocorrelação. Por exemplo, para encontrar os parâmetros p e q utilizou-se a Função de Autocorrelação da primeira diferença da série.

Partiu-se de um valor $c = \frac{2}{\sqrt{n}}$ onde n=168 pois a série foi diferenciada uma vez. Obteve-se, como referência para análise da série estacionária, o valor $c = 0,154$. Para determinar os valores de p e q, observa-se o primeiro valor abaixo do valor de referência $c = 0,154$, e depois, utilizam-se os valores da posição à qual o valor foi encontrado. Observa-se que se utiliza o valor absoluto; sendo assim obteve-se p=1 e q=1 (Figura 15).

Função de autocorrelação para d_Sudeste

***, **, * indicam significância aos níveis de 1%, 5% e 10% usando erro padrão $1/T^{0,5}$

Defas.	FAC		FACP		Estat. Q [p-valor]
1	-0,0243		-0,0243		0,1073 [0,743]
2	-0,1151		-0,1158		2,5328 [0,282]
3	-0,1814	**	-0,1900	**	8,5921 [0,035]
4	-0,2197	***	-0,2600	***	17,5286 [0,002]
5	0,0578		-0,0238		18,1513 [0,003]
6	0,1182		0,0243		20,7700 [0,002]
7	0,0001		-0,0812		20,7700 [0,004]
8	-0,1647	**	-0,2279	***	25,9093 [0,001]
9	-0,1220		-0,1615	**	28,7450 [0,001]
10	-0,1495	**	-0,2642	***	33,0309 [0,000]

Figura 15: Função de autocorrelação para parametrização do modelo SARIMA.
Fonte: O autor (2021).

Observa-se que foram testados, para o período de 01/2004 a 12/2018, vários modelos de acordo com a metodologia SARIMA.

4 RESULTADOS E DISCUSSÕES

Na Tabela 6 apresentam-se os resultados obtidos de 4 destes modelos. As análises dos erros e o critério de Akaike permitem verificar que os melhores resultados foram obtidos pelo modelo SARIMA(1,1,1)(2,1,3). Observa-se, também, que o U de Theil foi menor do que 1, o que indica uma previsão melhor que a previsão ingênua.

Modelo	MAE	RMSE	U de Theil	Akaike
SARIMA(1,1,1)(0,1,1)	0,278	0,354	0,769	162,47
SARIMA(1,1,1)(3,1,2)	0,270	0,346	0,746	160,24
SARIMA(1,1,1)(4,1,0)	0,280	0,359	0,776	162,87
SARIMA(1,1,1)(2,1,3)	0,238	0,304	0,662	157,73

Tabela 6: Resultados para cada modelo, especificando as métricas.
Fonte: O autor (2021).

Na sequência, foi efetuada a análise dos resíduos para avaliar a adequação deste modelo. Observa-se, da Figura 16, que os resíduos não são autocorrelacionados, pois os coeficientes de autocorrelação dos resíduos são estatisticamente iguais a zero, isto é, não ultrapassam os limites de confiança.

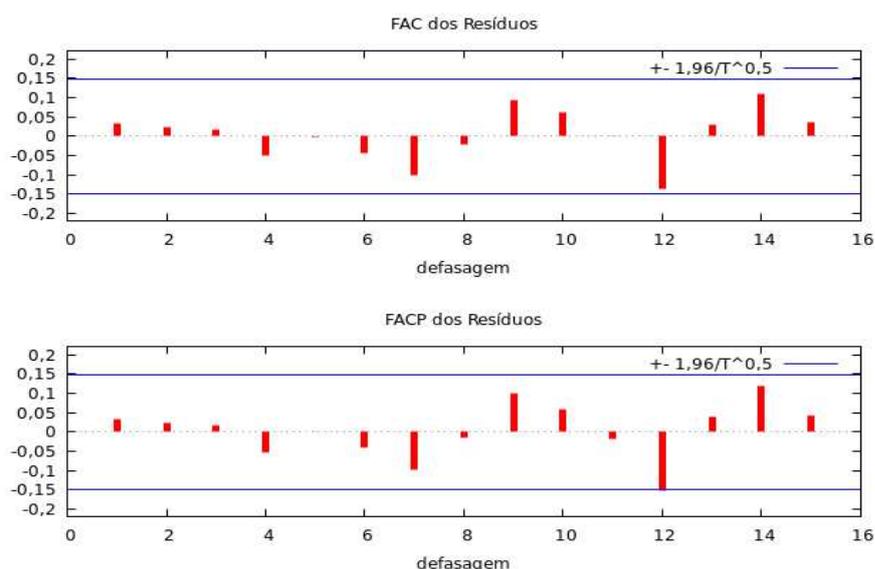


Figura 16: Função de autocorrelação dos resíduos da série original.
Fonte: O autor (2021).

Na Figura 17 apresenta-se o histograma dos resíduos. O GRETL exibe na parte superior esquerda da Figura 17 o resultado do Teste de DOomik-Hassen. O p-valor

entre os colchetes, revela a não rejeição da hipótese nula de normalidade dos resíduos.

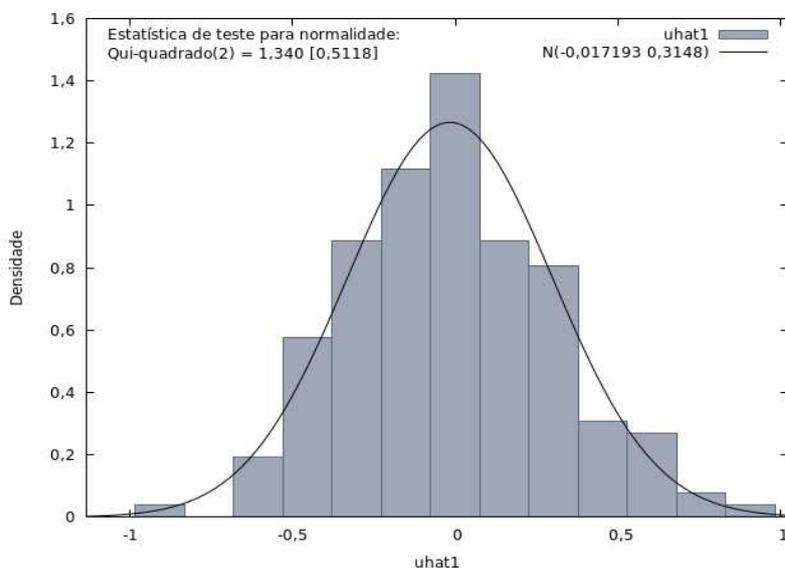


Figura 17: Teste de normalidade DOmik-Hassen.
Fonte: O autor (2021).

Depois da verificação dos resíduos avaliou-se, para o período de 01/2004 a 12/2018, a dispersão dos valores preditos pelo modelo em relação aos valores observados para a variável de resposta (Figura 18).

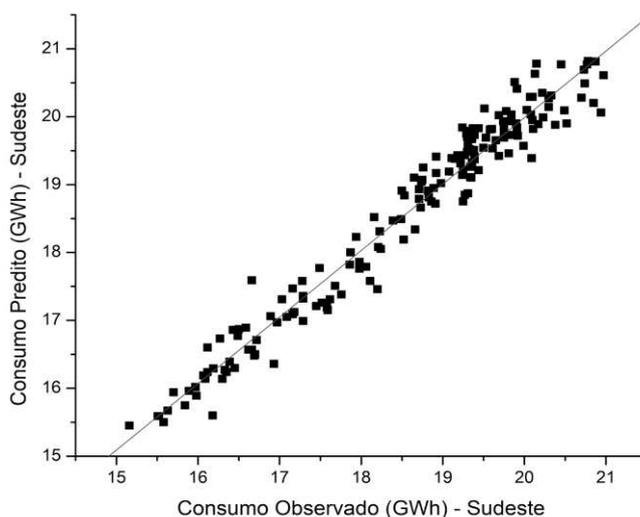


Figura 18: Dados de consumo de energia elétrica preditos em função do consumo observado.
Fonte: O autor (2021).

Na Figura 19 apresenta-se as curvas dos valores preditos, dos valores observados e do resíduo.

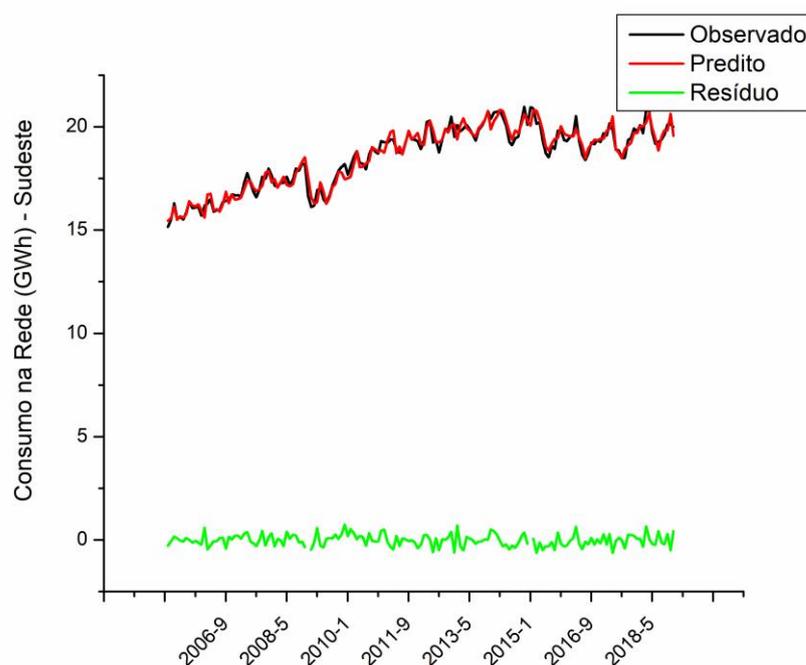


Figura 19: Séries: valores observados, valores preditos e resíduos.
Fonte: O autor (2021).

Observa-se que os dados reais apresentam uma boa correlação com os dados preditos para o consumo de energia na rede da Região Sudeste, já que as curvas dos valores preditos têm um bom ajuste com as curvas dos valores reais (observados). Observa-se também, da Figura 18, que não existe dispersão, porque os pontos estão próximos à linha de ajuste.

4.1 VALIDAÇÃO DA MELHOR PARAMETRIZAÇÃO OBTIDA

Na Tabela 7 são apresentados os dados observados, os dados preditos, os resíduos e os limites dos intervalos de confiança para os meses de janeiro, fevereiro, março, abril e maio de 2019.

Mês	Observado	Predito	Resíduo	Lim. Inferior	Lim. Superior
jan/19	20,76	20,37	0,331	19,72	21,02
fev/19	20,71	20,14	0,422	19,31	20,96
mar/19	20,6	20,6	0,475	19,67	21,53
abr/19	19,86	20,43	0,513	19,42	21,43
mai/19	20,24	19,9	0,543	18,84	20,97

Tabela 7: Resultados da previsão.
Fonte: O autor (2021).

Na Figura 20 apresenta-se um gráfico de colunas com os dados observados e preditos.

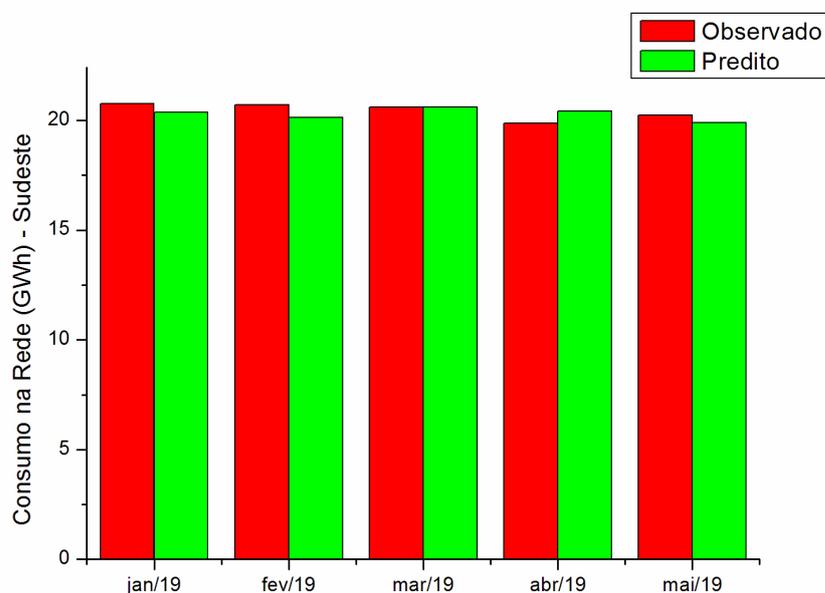


Figura 20: Consumo de energia na região sudeste: Valores observados e preditos de 2019.
Fonte: O autor (2020).

Pode-se notar, dos resultados apresentados na Tabela 7 e Figura 20, que os resultados reais e preditos estão muito próximos.

5 CONCLUSÕES

Este trabalho estimou o consumo de energia elétrica na rede da Região Sudeste do Brasil. Buscou-se determinar o comportamento futuro, a curto prazo, como forma de observar o comportamento do consumo de energia elétrica futuro a partir da dinâmica do passado.

Os modelos foram construídos baseados nos dados disponibilizados pela empresa de pesquisa energética (EPE). Observou-se que o modelo SARIMA(1,1,1)(2,1,3) foi o modelo que melhor se ajustou aos dados fornecidos pela empresa, gerando a melhor previsão para o consumo de energia elétrica da Região Sudeste do Brasil. A partir deste modelo, estimou-se os valores referentes aos meses de janeiro a maio de 2019. Os valores obtidos confirmam a tendência apresentada pelas variáveis reais.

Pode-se concluir que as previsões são de extrema importância para o conhecimento do comportamento futuro do consumo de energia elétrica na Região Sudeste, podendo servir muito bem como um grande indicador no planejamento de políticas públicas.

Por ter se mostrado confiável, mais trabalhos como este podem ser realizados, utilizando os mesmos métodos e expandindo-se para as outras regiões do Brasil, com o intuito de propiciar um melhor controle sobre a produção e distribuição de energia elétrica.

6 REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Atlas de energia elétrica do Brasil**. 3. ed. Brasília, DF, 2002. Disponível em <https://www.aneel.gov.br/documents/656835/14876406/2008_AtlasEnergiaEletricaBrasil3ed/297ceb2e-16b7-514d-5f19-16cef60679fb> . Acesso em: 20 out. 2019.

ALBUQUERQUE, Á. R. **Fluxo de Caixa em Risco: Uma Nova Abordagem para o Setor de Distribuição de Energia Elétrica**. PUC-Rio - Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p. 111. 2008.

BORBA, E. N. **Energia hidrelétrica e seus principais riscos hoje no Brasil: o caso dasPCHs**. 2015. 83p. Projeto de graduação, UFRJ, Rio de Janeiro, 2015. Disponível em:<http://monografias.poli.ufrj.br/monografias/monopoli10_014697.pdf>. Acesso em: 20 out.de 2019.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. San Francisco: Holden-Day, 1976.

BRESSAN, A.A. **Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais**. RAE. Eletrônica. v. 3, n. 1, 2004.

CARMINATI, J. G. de O.; SCALCO, P. R. **Relações de causalidade entre energia e crescimento econômico no Brasil**. Revista Brasileira de Energia, v. 19, n. 2, p. 355–374, 2013.

EHLERS, R. S. **Análise de séries temporais**. Curitiba: UFPR, 2005. Disponível em: <<http://www.each.usp.br/rvicente/AnaliseDeSeriesTemporais.pdf>> . Acesso em: 12 out. 2019.

EPE - Empresa de Pesquisa Energética. **Anuário estatístico de energia elétrica de 2018**. Disponível em <<http://epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>> . Acesso em: 30 abr. 2019.

FRANCELINO, D. A. R.; ARRAES, R. D. A. E. **Déficit de Energia Elétrica ante Cenários de Crescimento Econômico e o Potencial de Energia Eólica no Ceará**. Universidade Federal do Ceará. Fortaleza, p. 21. 2010.

GODINHO, T. S. **Análise do Modelo Sarima da série de consumo de energia elétrica da Região Sudeste no Brasil no período de janeiro de 2002 a março de 2015**. Universidade Federal de Alfenas. Varginha, p. 35. 2015.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: AMGH, 2011.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2 ed. O Texts: Austrália, 2013.

JUNIOR, L. M. C.; MELQUIADES, T. F.; MARTINS, K. L. C.; JUNIOR, E. P. S. FREITAS, G. P. **Previsão de consumo de eletricidade no nordeste brasileiro**. Engevista, v. 20, n. 3, 2018.

KHEIRKHAH, A.; AZADEH, A.; SABERI, M.; AZARON, A.; SHAKOURI, H. **Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis**. Computers & Industrial Engineering, v. 64, n. 1, 2013.

MADDALA, G. S. **Introduction to the theory and practice of econometrics**. New York: McGraw-Hill, 1992.

MATOS, O. C. **Econometria básica: teoria e aplicações**. 3. Ed. São Paulo: Atlas, 2000.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Blucher 2006.

MORETTIN, P.A. **Econometria Financeira: Um curso em séries temporais financeiras**. São Paulo: Ed: Blucher, 2008.

OLIVEIRA, A. **Novo modelo elétrico - papel ampliado para geração distribuída**. In Seminário INEE - Instituto Nacional de Eficiência Energética, 2004.

POLLI, D. A.; VIEIRA, N. N. **Modelagem estatística da série mensal de acidentes aéreos: um algoritmo automatizado para a seleção de modelos de previsão do número de ocorrências em curto prazo**. Revista Conexão Sipaer, v. 6, n. 1, 2015.

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

SILVA, C. A. G. **Previsão do preço da commodity café arábica: Uma aplicação da Metodologia Box-Jenkins**. Revista Espacios, v. 39, n. 04, 2018.

TODESCO, José Leomar; PIMENTEL, Francisco J. S.; BETTIOL, Arlan L. **O Uso de Famílias de Circuitos e Rede Neural Artificial para Previsão de Demanda de Energia Elétrica**. Revista Produção Online, Florianópolis, v. 4, n. 4, ago. 2004.

UNSIHUAY, V. C.; ZAMBRONI, A. C.; MARANGON, L. J. W.; BALESTRASSI, P. P., **Electricity demand and spot rice forecasting using evolutionary computation combined with chaotic nonlinear dynamic model**. International Journal of Electrical Power & Energy Systems, V. 32, n.2, p.108-116, Feb. 2010.

VEIGA, D. D. S.; FONSECA, V. M. **Análise do consumo de energia elétrica no Brasil**. Escola Nacional de Ciências e Estatística - ENCE. Rio de Janeiro, p. 94. 2002.

YIN, R. K. **Estudo de caso: planejamento e métodos**. Porto Alegre: Bookman, 2013.