

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
COORDENAÇÃO DE ENGENHARIA DE PRODUÇÃO
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

FRANCIELI REGINA MARTINS DOS SANTOS

**PREVISÃO DE MÉDIO PRAZO DE DEMANDA DE ENERGIA
ELÉTRICA DO SETOR INDUSTRIAL NA REGIÃO SUL E SUDESTE
DO BRASIL**

Trabalho de Conclusão de Curso

Medianeira

2019

FRANCIELI REGINA MARTINS DOS SANTOS

**PREVISÃO DE MÉDIO PRAZO DE DEMANDA DE ENERGIA
ELÉTRICA DO SETOR INDUSTRIAL NA REGIÃO SUL E SUDESTE
DO BRASIL**

Trabalho de conclusão de curso apresentado ao Curso de Graduação, em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná, como requisito parcial à disciplina de TCC2.

Orientador: Prof. Dr. Samuel Bellido Rodrigues

Coorientador: Prof. Dr. Levi Lopes Teixeira

Medianeira

2019



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
Câmpus Medianeira
DIRETORIA DE GRADUAÇÃO E EDUCAÇÃO PROFISSIONAL
Departamento Acadêmico de Produção e Administração
Curso de Graduação em Engenharia de Produção



TERMO DE APROVAÇÃO

PREVISÃO DE MÉDIO PRAZO DE DEMANDA DE ENERGIA ELÉTRICA DO SETOR INDUSTRIAL NA REGIÃO SUL E SUDESTE DO BRASIL

Por

Francieli Regina Martins dos Santos

Este trabalho de conclusão de curso foi apresentado no dia 21 de novembro de 2019 como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná, Câmpus Medianeira. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Samuel Bellido Rodrigues
Universidade Tecnológica Federal do Paraná

Prof. Dr. Levi Lopes Teixeira
Universidade Tecnológica Federal do Paraná

Prof. Dr. Jairo Marlon Correa
Universidade Tecnológica Federal do Paraná

Profa. Dra. Tássia Hickmann
Universidade Tecnológica Federal do Paraná

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso-.

À minha família...

AGRADECIMENTOS

Agradeço especialmente aos meus pais, Rozinei e Francisco, por todo carinho e por fazerem de tudo para eu concluir mais essa etapa na minha vida.

Aos meus orientadores Prof Dr. Samuel e Prof Dr. Levi por terem contribuído para a Autoria deste trabalho.

A todos os meus amigos que ajudaram e motivaram em todas as dificuldades no decorrer do curso.

Agradeço ao meu namorado por toda motivação.

.

.

.

.

.

.

.

“Quando tudo parecer dar errado em sua vida, lembre-se que o avião
decola contra o vento, e não a favor”.

Henry Ford.

RESUMO

SANTOS, Francieli R. M.. **Previsão de médio prazo de demanda de energia elétrica do setor industrial na região sul e sudeste do Brasil**. 2019. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

A análise e previsão de demanda tem papel fundamental no planejamento e otimização dos processos, recursos e investimentos, em particular para o bom êxito do setor energético. O objetivo deste estudo foi utilizar os métodos de previsão ETS, SARIMA e SARIMAX com variáveis PIB e IBCR para realizar a modelagem da demanda de energia elétrica do setor industrial da região sul e sudeste do Brasil. Após a modelagem foram utilizadas as medidas de acurácia MAPE e MAE a fim de identificar o método a ser utilizado. Os melhores métodos apresentaram MAPE dentro da amostra de 1,49% para região sudeste e 1,81% para a região sul.

Palavras-chave: Projeção; Métodos estatísticos; Energia.

ABSTRACT

SANTOS, Francieli R. M.. **Forecast of demand for electricity consumed by the industrial sector in the South and Southeast of Brazil**. 2018. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

Demand analysis and forecasting play a key role in the planning and optimization of processes, resources and investments, in particular for the success of the energy sector. The objective of this study was to use the ETS, SARIMA and SARIMAX forecasting methods with GDP and IBCR variables to model the electric energy demand of the industrial sector of southern and southeastern Brazil. After modeling, the MAPE and MAE accuracy measures were used to identify the method to be used. The best methods presented MAPE within the sample of 1.49% for the southeastern region and 1.81% for the south region.

Keys-words: Projection; Statistical methods; Energy.

LISTA DE FIGURAS

Figura 1: Etapas de modelo de previsão	15
Figura 2: Alguns métodos de previsão de demanda	16
Figura 3: Equação dos modelos ETS com erros Aditivos	18
Figura 4: Equação dos modelos ETS com erros multiplicativos.....	19
Figura 5: Classificação da pesquisa.....	32
Figura 6: Etapas da pesquisa.....	42
Figura 7: Fluxograma de previsão do modelo ETS	43
Figura 9: Fluxograma da previsão da série de dados PIB.....	45
Figura 10: Etapas da previsão da série de dados da variável IBCR	46
Figura 11: Fluxograma de previsão do modelo SARIMAX	47

LISTA DE TABELA

Tabela 1: Classificação do coeficiente de Pearson	26
Tabela 2: Característica da série de dados de energia da região Sudeste	34
Tabela 3: Característica da série de dados de energia da região Sudeste	36
Tabela 4: Distribuição de frequência da série de dados PIB	38
Tabela 5: Correlação da variável PIB	38
Tabela 6: Características da série de dados IBCR Sudeste	40
Tabela 7: Características da série de dados IBCR Sudeste	41
Tabela 8:Comparativo de AIC dos modelos ETS	49
Tabela 9: Medidas de acurácia da previsão da região Sudeste via modelo ETS.....	50
Tabela 10: Coeficientes da equação do modelo SARIMA (4,0,4)(1,0,2)	50
Tabela 11: Comparativos de AIC dos principais modelos SARIMA testados	50
Tabela 12: Medidas de acurácia da previsão via modelo SARIMA para região sudeste	51
Tabela 13: Medidas de acurácia da previsão da variável PIB	52
Tabela 14:Coeficientes da equação do modelo SARIMAX (0,0,0)(1,0,1).....	52
Tabela 15: Comparativo de AIC dos principais modelos SARIMAX com variável PIB	53
Tabela 16: Medidas de acurácia da previsão do modelo SARIMAX – PIB para região Sudeste	53
Tabela 17: Medidas de acurácia das modelagens da variável IBCR Sudeste	54
Tabela 18: Coeficientes da equação do modelo SARIMAX com variável IBCR.....	54
Tabela 19: Comparativo de AIC dos principais modelos SARIMAX com variável IBCR	55
Tabela 20: Medidas de acurácia – SARIMAX(IBCRR) Sudeste	56
Tabela 21: Coeficientes da equação do modelo SARIMAX com variáveis PIB e IBCR	56
Tabela 22: Comparativo de AIC dos principais modelos SARIMAX com variáveis PIB e IBCR.....	56
Tabela 23:Medidas de acurácia – SARIMAX – PIB e IBCR Sudeste	57
Tabela 24: Comparativo de AIC dos principais modelo ETS – Região Sul	58

Tabela 25: Medidas de acurácia da previsão da região Sul via modelo ETS.....	59
Tabela 26: Coeficientes da equação do modelo SARIMA – Região Sul	59
Tabela 27: Comparativo de AIC dos principais modelos SARIMA – Região Sul.....	60
Tabela 28: Medidas de acurácia da previsão da região Sul via modelo SARIMA	61
Tabela 29: Coeficientes da equação do modelo SARIMAX com variável PIB– Região Sul	61
Tabela 30:Comparativo de AIC dos principais modelos SARIMAX com variável PIB – Região Sul.....	61
Tabela 31: Medidas de acurácia da previsão da região Sul via modelo SARIMAX (PIB)	62
Tabela 32:Medidas de acurácia das modelagens da variável IBCR (SUL)	63
Tabela 33: Coeficientes da equação do modelo SARIMAX com variável IBCR– Região Sul	63
Tabela 34: Comparativo de AIC dos principais modelos SARIMAX (IBCR) – Região Sul	63
Tabela 35: Medidas de acurácia – SARIMAX(IBCR) Sul	64
Tabela 36: Coeficientes da equação do modelo SARIMAX com variáveis PIB e IBCR– Região Sul.....	65
Tabela 37: Comparativo de AIC dos principais modelos SARIMAX (PIB e IBCR) – Região Sul.....	65
Tabela 38: Medidas de acurácia – SARIMAX(PIB e IBCR) Sul.....	66
Tabela 39: Comparativo entre medidas de acurácia das previsões da região Sudeste	66
Tabela 40: Medidas de acurácia mensal, dados reais e previsão– Região Sudeste	67
Tabela 41: Medidas de acurácia mensal– Região sul	68

LISTA DE GRÁFICOS

Gráfico 1: Série de dados de energia consumida pelo setor industrial na região Sudeste	33
Gráfico 2: Distribuição de frequência do consumo de energia do setor industrial na região Sudeste	34
Gráfico 3: Consumo de energia mensal do setor industrial da região Sul.....	35
Gráfico 4: Distribuição de frequência do consumo de energia do setor industrial na região Sul	36
Gráfico 5: Série de dados PIB – Brasil	37
Gráfico 6: Distribuição de frequência do PIB brasileiro	37
Gráfico 7: Série de dados do IBCR da região Sudeste	39
Gráfico 8: Distribuição de frequência da série de dados IBCR Sudeste	39
Gráfico 9:Série de dados IBCR região Sul	41
Gráfico 10:Distribuição de frequência da série de dados IBCR Sudeste	41
Gráfico 11: Gráfico dos dados reais e da previsão obtida através do método ETS - Região Sudeste.....	49
Gráfico 12: Gráfico dos dados reais e da previsão obtida através do método SARIMA – Região Sudeste.....	51
Gráfico 13:Série de dados reais e da previsão obtida através do método SARIMAX PIB – Região Sul	53
Gráfico 14:Série de dados reais e da previsão obtida através do método SARIMAX IBCR – Região Sudeste	55
Gráfico 15: Série de dados reais e da previsão obtida através do método SARIMAX PIB e IBCR – Região Sudeste.....	57
Gráfico 16: Série de dados reais e da previsão obtida através do método ETS – Região Sul	59
Gráfico 17: Série de dados reais e da previsão obtida através do método SARIMA – Região Sul.....	60
Gráfico 18: Série de dados reais e da previsão obtida através do método SARIMAX (PIB) – Região Sul.....	62
Gráfico 19: Série de dados reais e da previsão obtida através do método SARIMAX (IBCR) – Região Sul.....	64

Gráfico 20: Série de dados reais e da previsão obtida através do método SARIMAX (IBCR) – Região Sul.....	66
Gráfico 21:Comparativos entre os dados reais e a previsão pelo modelo ETS.....	67
Gráfico 22: Comparativo de erros da região sul.....	68
Gráfico 23: Comparativos de resultado de modelos - sul.....	69

LISTA DE SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
AR	Auto Regressivo
ARIMA	Modelo Auto Regressivo Integrado de Médias móveis
ARMA	Modelo Auto Regressivo de Médias Móveis
DOLS	Mínimos Quadrados Ordinários Dinâmicos
EPE	Empresa de Pesquisa Energética
FAP	Função de Correlação Parcial
FAS	Função de Correlação Simples
HW	<i>Holt-Winters</i>
IBCR	Índice de Atividade Econômica Regional
IBGE	Instituto Brasileiro de Geografia e Estatística
LEAP	<i>Long Range Energy Alternatives Planning System</i>
MA	Média Móvel
MAE	Erro Absoluto Médio
MAPE	Erro Percentual Absoluto Médio
ME	Erro Médio
MSE	Erro Quadrático Médio
PIB	Produto Interno Bruto
RMSE	Raiz do Erro Quadrático Médio
RNA	Redes Neurais
SARIMA	Modelo Sazonal Auto Regressivo Integrado de Médias Móveis
SARIMAX	Modelo Sazonal Auto Regressivo Integrado de Médias Móveis e Variáveis Exógenas
SGR	Sistema Gerenciador de Series Temporais do Banco Central
SVR	<i>Support Vector Regression</i>
VECM	Modelo de Auto Regressão Vetorial com correção de erro

SUMÁRIO

1 INTRODUÇÃO	11
2 OBJETIVOS	13
2.1 OBJETIVO GERAL	13
2.2 OBJETIVOS ESPECÍFICOS.....	13
3 REVISÃO DE LITERATURA	14
3.1 PREVISÃO DE DEMANDA.....	14
3.2 MODELOS ESTATÍSTICOS DE PREVISÃO DE DEMANDA.....	16
3.2.1 Séries Temporais	17
3.2.1.1 Modelos ETS.....	17
3.2.1.2 ARIMA.....	19
3.2.1.3 SARIMA.....	22
3.2.1.4 SARIMAX	22
3.3 VARIÁVEIS EXÓGENAS	24
3.3.1 Produto Interno Bruto (PIB).....	24
3.3.2 Índice de Atividade Econômica Regional (IBCR)	25
3.3.3 Correlação de Variáveis	25
3.3.3.1 Correlação de Pearson.....	25
3.4 CRITÉRIO DE INFORMAÇÃO DE AKAIKE (AIC)	27
3.5 MEDIDAS DE ACURÁCIA	27
3.6 TRABALHOS RELACIONADOS	29
4 MATERIAIS E MÉTODOS	31
4.1 CLASSIFICAÇÃO DA PESQUISA	31
4.2 MATERIAIS	33
4.2.1 Série de dados da Região Sudeste.....	33
4.2.2 Série de Dados Região Sul	35
4.2.3 Série de dados do PIB.....	37
4.2.4 Série de dados IBCR – Sudeste.....	38
4.2.5 Série de dados IBCR – Sul.....	40
4.3 MÉTODOS	42
4.3.1 Método ETS	43
4.3.2 Método SARIMA.....	44
4.3.3 Método SARIMAX	45

4.3.3.1 Modelagem variável PIB.....	45
4.3.3.2 Modelagem da variável IBCR.....	46
4.3.3.3 Modelagem SARIMAX.....	46
5 RESULTADOS.....	48
5.1 REGIÃO SUDESTE.....	48
5.1.1 ETS (Error, Trend, Season).....	48
5.1.2 SARIMA.....	50
5.1.3 SARIMAX com variável PIB.....	51
5.1.3.1 Modelagem PIB.....	52
5.1.3.2 Modelagem SARIMAX.....	52
5.1.4 SARIMAX com variável IBCR.....	54
5.1.4.1 Modelagem IBCR.....	54
5.1.4.2 Modelagem SARIMAX.....	54
5.1.5 SARIMAX com as variáveis PIB e IBCR.....	56
5.2 REGIÃO SUL.....	57
5.2.1 ETS (Error, Trend, Season).....	57
5.2.2 SARIMA.....	59
5.2.3 SARIMAX com variável PIB.....	61
5.2.4 SARIMAX com a variável IBCR.....	62
5.2.4.1 Modelagem IBCR sul.....	62
5.2.4.2 Modelagem SARIMAX.....	63
5.2.5 SARIMAX com as variáveis PIB e IBCR.....	64
5.3 COMPARATIVO E APRESENTAÇÃO DA PREVISÃO.....	66
5.3.1 Região Sudeste.....	66
5.3.2 Região Sul.....	68
6 CONCLUSÃO.....	70
7 SUGESTÕES PARA TRABALHOS FUTUROS.....	71
REFERÊNCIAS.....	72

1 INTRODUÇÃO

No decorrer do século XX, o Brasil apresentou uma grande expansão econômica devido à industrialização, o que desencadeou um aumento considerável no consumo de energia primária. De 1970 a 2000 ocorreu um crescimento na taxa de urbanização e instalações industriais que gerou a ampliação da capacidade geradora das hidrelétricas, além de expandir a distribuição por todo território brasileiro (TOLMASQUIM, 2007).

O consumo de energia elétrica é influenciado tanto pela capacidade da população em obter bens e serviços tecnologicamente avançados como eletrodomésticos, eletroeletrônicos, automóveis (que para a utilização necessitam de energia), quanto nas atividades dos setores de serviço, industrial, comercial e agropecuário (ANEEL, 2008).

O sistema brasileiro de produção de energia elétrica é predominantemente de geração hídrica, que segundo dados da Aneel (2017) essa fonte possui um pouco mais de 60% da geração total. O imenso potencial hidrelétrico brasileiro enfatiza a necessidade do planejamento da expansão da geração, tendo em vista que os prazos de construção de usinas hidroelétricas são bem maiores que os de usinas termoelétricas, por exemplo.

Desde 2003 o órgão que realiza estudos e projeções acerca do consumo e demanda de energia elétrica do país é a Empresa de Pesquisa Energética (EPE). Além de computar e disponibilizar os dados, ela realiza projeções a longo prazo (de 10 a 40 anos) que são publicados por meio de relatórios *online*, fazem revisão quadrimestral visando acompanhar as projeções de médio prazo (cinco anos) e publicam uma resenha mensal do mercado que contém um acompanhamento do consumo do sistema (EPE, 2018).

Segundo dados da EPE (2018), em 2017 o consumo de energia teve um crescimento médio de 2,7%, sendo que o setor que mais consome é o industrial, seguido de residencial, comercial e outros. Neste ano, o setor industrial apresentou um crescimento de 1,1% em relação a 2016; o setor residencial crescimento de 0,8%; comercial de 0,3%; e outros de 0,7%.

As distribuidoras devem realizar a previsão avaliando o crescimento de todos os setores da economia nas regiões que são atendidas por elas. Tal previsão precisa

ser confiável o suficiente para que possa suprir as necessidades em períodos especiais que afetam a demanda, tal como racionamento (como por exemplo o apagão de 2000) e períodos de crise (como exemplo a crise hídrica de 2015).

Portanto, conhecer a sua demanda é importante tanto para políticas públicas como estratégicas. Como a energia elétrica é um dos pilares de sustentação da produção econômica de um país e um insumo não estocável, há uma grande necessidade de um planejamento preciso visto que a produção acima da demanda resulta em desperdício, onde o prejuízo é rateado entre os consumidores. E produção abaixo pode resultar em apagões.

Diante deste cenário, o objetivo deste estudo foi projetar a demanda de energia do setor industrial da região Sul e Sudeste para o período de julho de 2018 a junho de 2019 utilizando modelos estatísticos e incluindo a série de dados do Produto Interno Bruto (PIB) e índice de Desenvolvimento Econômico Regional (IBCR) como variáveis exógenas. A partir dos resultados das projeções, realizou-se um comparativo com os erros dentro da amostra a fim de se definir qual método apresentou melhor acurácia.

As regiões Sul e Sudeste foram as escolhidas pois apresentam os maiores números de unidades consumidoras e PIB. A região Sudeste apresenta o maior nível de desenvolvimento industrial, concentra cerca de 67,7% das indústrias do Brasil, seguido da região Sul com 14,1% (IBGE, 2017).

2 OBJETIVOS

2.1 OBJETIVO GERAL

Prever a demanda de energia elétrica do setor industrial na região Sul e Sudeste do Brasil no período de julho de 2018 a junho de 2019 utilizando métodos estatísticos de previsão com variáveis exógenas.

2.2 OBJETIVOS ESPECÍFICOS

- i. Analisar as séries históricas mensais da demanda de energia elétrica da região Sul e Sudeste para o período de janeiro de 2002 a junho 2018.
- ii. Aplicar os métodos de previsão ETS, SARIMA e SARIMAX para prever o consumo mensal de julho de 2018 a junho de 2019.
- iii. Utilizar as séries PIB e IBRCR como variáveis exógenas
- iv. Comparar o desempenho dos modelos obtidos com a demanda real através das medidas de acurácia: erro percentual absoluto médio (MAPE) e erro absoluto médio (MAE).
- v. Identificar o modelo a ser utilizado através das medidas de acurácia MAPE e MAE.

3 REVISÃO DE LITERATURA

Nessa seção serão abordados conceitos e características acerca dos assuntos relevantes para o bom desenvolvimento desta pesquisa, sob o ponto de vista de vários autores. Os principais tópicos percorridos são: previsão de demanda; métodos estatísticos; variáveis exógenas; medidas de acurácia; e trabalhos relacionados.

3.1 PREVISÃO DE DEMANDA

Demanda é a relação entre a quantidade de clientes e o consumo de bens e serviços ofertados por uma organização, esta pode ser influenciada por uma série de fatores que vão desde condições macroeconômicas até questões operacionais, como disponibilidade e preço final (LUSTOSA et al., 2008). O objetivo de se realizar uma previsão é utilizar as informações disponíveis para melhorar as atividades futuras, permitindo assim um melhor dimensionamento de pessoal, matéria-prima, capital, estoque e inúmeros outros fatores (MONKS, 1987).

As previsões têm papel importante no processo de planejamento de sistemas, pois permitem que os administradores prevejam os resultados futuros e planejem adequadamente suas ações atuais (TUBINO, 2009). Elas podem ser de curto, médio ou longo prazo. Para as de curto prazo (até três meses) são utilizados modelos estatísticos a partir de medidas ou ajustamentos de metas, as de médio (até dois ou três anos) e as de longo prazo (acima de dois anos), são utilizados modelos explicativos ou econométricos (MARTINS; LAUGEN, 2015).

Previsões de curto prazo são necessárias para a programação de pessoal, produção e transporte, normalmente utilizada no planejamento e controle da produção. Previsões de médio prazo são utilizadas na tomada de pequenas decisões estratégicas, como determinar a quantidade de matéria-prima futura a ser comprada, mão-de-obra e equipamentos/maquinário. E as previsões de longo prazo são necessárias para decisões estratégicas como novos investimentos, lançamentos de novos produtos e devem levar em consideração fatores econômicos, ambientais e recursos internos (HYNDMAN, 2008)

Fernandes e Godinho Filho (2010) citam algumas características fundamentais para elaborar uma boa previsão. São elas: o modelo deve ser alterado caso as suposições originais não sejam mais verdadeiras; os erros não devem ser motivos de preocupação, pois alguns são inevitáveis e podem ser minimizados; fazer uma previsão de curto prazo diminui o nível de incerteza e erro; a quantidade de dados históricos considerados no modelo deve ser coerente com o que se deseja projetar; devem ser expressas em unidades significativas; e o modelo tem que ser fácil de compreender e simples de utilizar.

Tubino (2009) afirma que um modelo de previsão de demanda pode ser elaborado em cinco etapas, apresentadas na Figura 1.

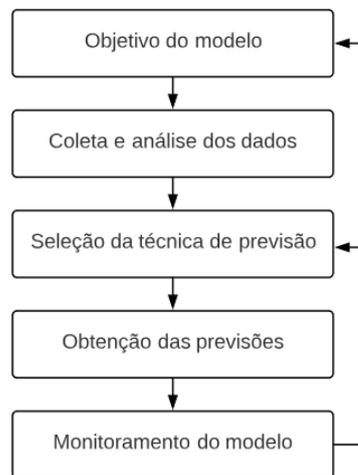


Figura 1: Etapas de modelo de previsão
Fonte: Tubino, 2009 p.16

Inicialmente é determinado o objetivo do modelo, a razão pela qual a previsão é necessária, após isso são realizadas a coleta e análise dos dados que serão muito importantes para a próxima etapa, que consiste na seleção da técnica de previsão adequada. A quarta etapa resume-se na obtenção das previsões e a última é o monitoramento das previsões, que consiste em comparar o real (à medida que as previsões forem alcançadas), com o resultado obtido no modelo (TUBINO, 2009).

3.2 MODELOS ESTATÍSTICOS DE PREVISÃO DE DEMANDA

Como especificado na Figura 1, a definição da técnica é um dos passos para a Autoria da previsão. Os modelos de previsão podem ser divididos em dois grandes grupos: qualitativos e quantitativos. As técnicas qualitativas são as que se baseiam na intuição, emoção, experiências pessoais e valores, elas não podem ser demonstradas matematicamente e normalmente são realizadas por meio de consultas a opinião de clientes, vendedores, executivos ou especialistas. Já as técnicas quantitativas, utilizam dados passados para a realização da previsão (FERNANDES; GODINHO FILHO, 2010; TUBINO, 2009).

Os métodos descritos acima estão exemplificados na Figura 2.

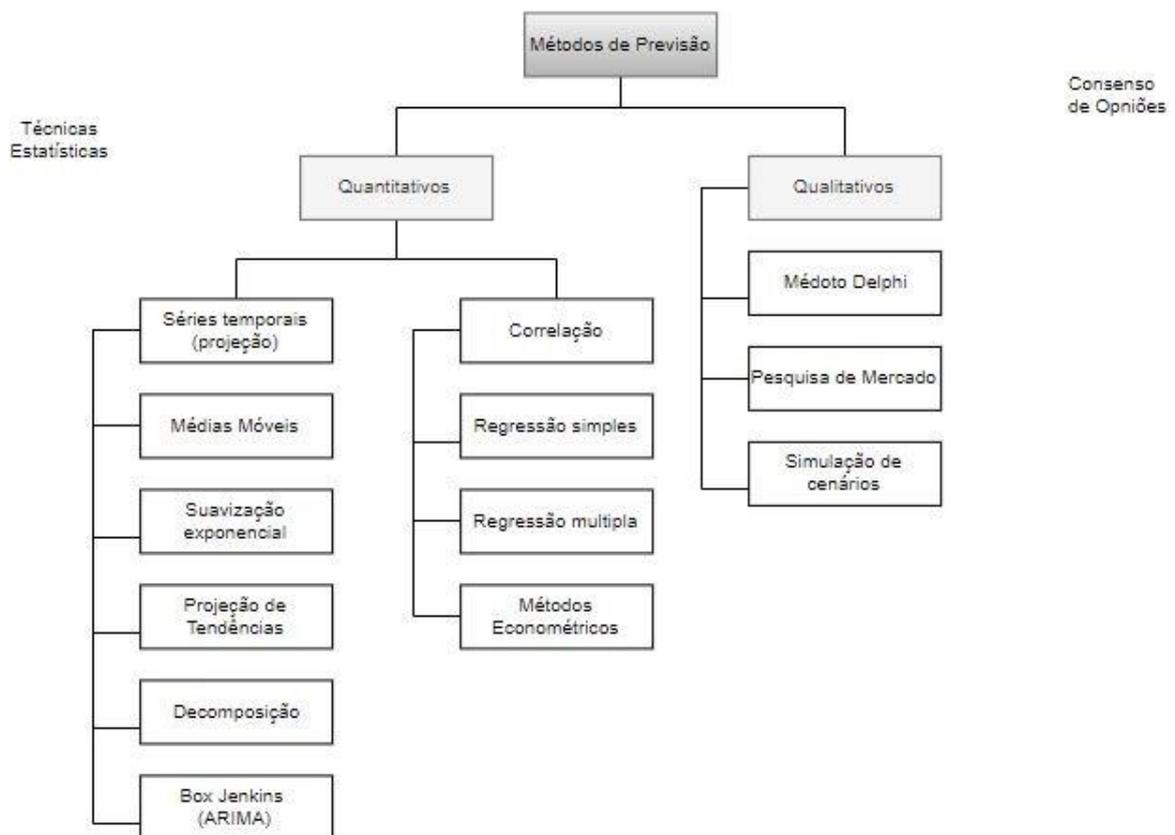


Figura 2: Alguns métodos de previsão de demanda
 Fonte: Lustosa et al (2008) p.57

Os modelos que foram utilizados para a realização deste trabalho, são abordados na próxima seção.

3.2.1 Séries Temporais

“Série temporal é um conjunto de observações ordenadas no tempo”. Os métodos de previsão que utilizam séries temporais são definidos por dados históricos, ou seja, é realizada a previsão a partir de dados passados (FERNANDES; GODINHO FILHO, 2010, p.29)

Segundo Monks (1987), as séries temporais podem ser constituídas de tendência, T; ciclo, C; sazonalidade, S. A previsão é realizada por meio de uma função dessas componentes como demonstra a Equação (1).

$$Y_c = T \cdot C \cdot S \cdot \quad (1)$$

Moreira (1993), define os quatro comportamentos ou efeitos associados às séries temporais:

- a) Efeito tendência: É o caso de a série apresentar uma tendência de crescimento ou decrescimento no tempo.
- b) Efeito sazonal: É o caso de a série apresentar padrões em determinado período do ano.
- c) Ciclo de negócios: É o caso de a série apresentar variações causadas por flutuações econômicas.
- d) Variações irregulares ou acaso: É quando a série apresenta variações por um curto ou curtíssimo período de tempo, por causas não identificadas.

3.2.1.1 Modelos ETS

Os modelos ETS (*error, trend, seasonal*) envolvem erro, tendência e sazonalidade, como o próprio nome sugere. O erro pode ser multiplicativo (M) ou aditivo (A), a tendência pode não existir (N), ser multiplicativa (M), multiplicativa amortecida (Md), aditiva (A) ou aditiva amortecida (Ad) e a sazonalidade pode não ocorrer (N), ser multiplicativa (M) ou aditiva (A) (HYNDMAN, 2008).

A Figura 3 apresenta as equações dos modelos ETS que contém erros aditivos.

Trend	Seasonal		
	N	A	M
N	$\mu_t = \ell_{t-1}$ $\ell_t = \ell_{t-1} + \alpha \varepsilon_t$	$\mu_t = \ell_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \alpha \varepsilon_t$ $s_t = s_{t-m} + \gamma \varepsilon_t$	$\mu_t = \ell_{t-1} s_{t-m}$ $\ell_t = \ell_{t-1} + \alpha \varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma \varepsilon_t / \ell_{t-1}$
A	$\mu_t = \ell_{t-1} + b_{t-1}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha \varepsilon_t$ $b_t = b_{t-1} + \beta \varepsilon_t$	$\mu_t = \ell_{t-1} + b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha \varepsilon_t$ $b_t = b_{t-1} + \beta \varepsilon_t$ $s_t = s_{t-m} + \gamma \varepsilon_t$	$\mu_t = (\ell_{t-1} + b_{t-1}) s_{t-m}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha \varepsilon_t / s_{t-m}$ $b_t = b_{t-1} + \beta \varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma \varepsilon_t / (\ell_{t-1} + b_{t-1})$
A _d	$\mu_t = \ell_{t-1} + \phi b_{t-1}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha \varepsilon_t$ $b_t = \phi b_{t-1} + \beta \varepsilon_t$	$\mu_t = \ell_{t-1} + \phi b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha \varepsilon_t$ $b_t = \phi b_{t-1} + \beta \varepsilon_t$ $s_t = s_{t-m} + \gamma \varepsilon_t$	$\mu_t = (\ell_{t-1} + \phi b_{t-1}) s_{t-m}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha \varepsilon_t / s_{t-m}$ $b_t = \phi b_{t-1} + \beta \varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma \varepsilon_t / (\ell_{t-1} + \phi b_{t-1})$
M	$\mu_t = \ell_{t-1} b_{t-1}$ $\ell_t = \ell_{t-1} b_{t-1} + \alpha \varepsilon_t$ $b_t = b_{t-1} + \beta \varepsilon_t / \ell_{t-1}$	$\mu_t = \ell_{t-1} b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} b_{t-1} + \alpha \varepsilon_t$ $b_t = b_{t-1} + \beta \varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma \varepsilon_t$	$\mu_t = \ell_{t-1} b_{t-1} s_{t-m}$ $\ell_t = \ell_{t-1} b_{t-1} + \alpha \varepsilon_t / s_{t-m}$ $b_t = b_{t-1} + \beta \varepsilon_t / (s_{t-m} \ell_{t-1})$ $s_t = s_{t-m} + \gamma \varepsilon_t / (\ell_{t-1} b_{t-1})$
M _d	$\mu_t = \ell_{t-1} b_{t-1}^\phi$ $\ell_t = \ell_{t-1} b_{t-1}^\phi + \alpha \varepsilon_t$ $b_t = b_{t-1}^\phi + \beta \varepsilon_t / \ell_{t-1}$	$\mu_t = \ell_{t-1} b_{t-1}^\phi + s_{t-m}$ $\ell_t = \ell_{t-1} b_{t-1}^\phi + \alpha \varepsilon_t$ $b_t = b_{t-1}^\phi + \beta \varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma \varepsilon_t$	$\mu_t = \ell_{t-1} b_{t-1}^\phi s_{t-m}$ $\ell_t = \ell_{t-1} b_{t-1}^\phi + \alpha \varepsilon_t / s_{t-m}$ $b_t = b_{t-1}^\phi + \beta \varepsilon_t / (s_{t-m} \ell_{t-1})$ $s_t = s_{t-m} + \gamma \varepsilon_t / (\ell_{t-1} b_{t-1}^\phi)$

Figura 3: Equação dos modelos ETS com erros Aditivos
Fonte: Hyndman (2008) p. 21

A Figura 4 apresenta a equação dos modelos ETS com erros multiplicativos.

Trend	Seasonal		
	N	A	M
N	$\mu_t = \ell_{t-1}$ $\ell_t = \ell_{t-1}(1 + \alpha \varepsilon_t)$	$\mu_t = \ell_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \alpha(\ell_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(\ell_{t-1} + s_{t-m})\varepsilon_t$	$\mu_t = \ell_{t-1}s_{t-m}$ $\ell_t = \ell_{t-1}(1 + \alpha \varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma \varepsilon_t)$
A	$\mu_t = \ell_{t-1} + b_{t-1}$ $\ell_t = (\ell_{t-1} + b_{t-1})(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1} + \beta(\ell_{t-1} + b_{t-1})\varepsilon_t$	$\mu_t = \ell_{t-1} + b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + b_{t-1} + \alpha(\ell_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = b_{t-1} + \beta(\ell_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(\ell_{t-1} + b_{t-1} + s_{t-m})\varepsilon_t$	$\mu_t = (\ell_{t-1} + b_{t-1})s_{t-m}$ $\ell_t = (\ell_{t-1} + b_{t-1})(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1} + \beta(\ell_{t-1} + b_{t-1})\varepsilon_t$ $s_t = s_{t-m}(1 + \gamma \varepsilon_t)$
A _d	$\mu_t = \ell_{t-1} + \phi b_{t-1}$ $\ell_t = (\ell_{t-1} + \phi b_{t-1})(1 + \alpha \varepsilon_t)$ $b_t = \phi b_{t-1} + \beta(\ell_{t-1} + \phi b_{t-1})\varepsilon_t$	$\mu_t = \ell_{t-1} + \phi b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1} + \phi b_{t-1} + \alpha(\ell_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = \phi b_{t-1} + \beta(\ell_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$ $s_t = s_{t-m} + \gamma(\ell_{t-1} + \phi b_{t-1} + s_{t-m})\varepsilon_t$	$\mu_t = (\ell_{t-1} + \phi b_{t-1})s_{t-m}$ $\ell_t = (\ell_{t-1} + \phi b_{t-1})(1 + \alpha \varepsilon_t)$ $b_t = \phi b_{t-1} + \beta(\ell_{t-1} + \phi b_{t-1})\varepsilon_t$ $s_t = s_{t-m}(1 + \gamma \varepsilon_t)$
M	$\mu_t = \ell_{t-1}b_{t-1}$ $\ell_t = \ell_{t-1}b_{t-1}(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1}(1 + \beta \varepsilon_t)$	$\mu_t = \ell_{t-1}b_{t-1} + s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1} + \alpha(\ell_{t-1}b_{t-1} + s_{t-m})\varepsilon_t$ $b_t = b_{t-1} + \beta(\ell_{t-1}b_{t-1} + s_{t-m})\varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma(\ell_{t-1}b_{t-1} + s_{t-m})\varepsilon_t$	$\mu_t = \ell_{t-1}b_{t-1}s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1}(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1}(1 + \beta \varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma \varepsilon_t)$
M _d	$\mu_t = \ell_{t-1}b_{t-1}^\phi$ $\ell_t = \ell_{t-1}b_{t-1}^\phi(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1}^\phi(1 + \beta \varepsilon_t)$	$\mu_t = \ell_{t-1}b_{t-1}^\phi + s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1}^\phi + \alpha(\ell_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t$ $b_t = b_{t-1}^\phi + \beta(\ell_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t / \ell_{t-1}$ $s_t = s_{t-m} + \gamma(\ell_{t-1}b_{t-1}^\phi + s_{t-m})\varepsilon_t$	$\mu_t = \ell_{t-1}b_{t-1}^\phi s_{t-m}$ $\ell_t = \ell_{t-1}b_{t-1}^\phi(1 + \alpha \varepsilon_t)$ $b_t = b_{t-1}^\phi(1 + \beta \varepsilon_t)$ $s_t = s_{t-m}(1 + \gamma \varepsilon_t)$

Figura 4: Equação dos modelos ETS com erros multiplicativos
 Fonte: Hyndman (2008) p.22

Em que:

μ_t = Estimativa de previsão

ℓ_t = Estimativa de nível, $t = 1, 2, 3 \dots m$

b_t = Estimativa de tendência, $t = 1, 2, 3 \dots m$

s_t = Estimativa de sazonalidade, $t = 1, 2, 3 \dots m$

α = Parâmetro de estimação para nível

β = Parâmetro de estimação para tendência

γ = Parâmetro de estimação para sazonalidade

3.2.1.2 ARIMA

Os modelos ARIMA possuem uma classificação de acordo com sua ordem (p,d,q), no qual p é o número de defasagens da série, d é a ordem de diferenciação e q, o número de defasagens dos ruídos. Em que ruídos brancos são os erros de estimação com distribuição normal, variância constante e não correlacionados (BOX;

JENKINS, 2015).

O da combinação de três componentes denominados “filtros”: o componente auto regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA) (FAVA, 2000).

De acordo com Werner e Ribeiro (2003), um modelo auto regressivo (AR) é composto pelos seus valores passados e o ruído branco. Esse modelo é representado conforme a Equação 2, descrita por Morettin e Tolo (2006).

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t, \quad \tilde{Z}_t = Z_t - \mu \quad (2)$$

Em que:

ϕ_i = Parâmetros da estrutura auto-regressiva, $i = 1, \dots, p$

ε_t = ruído branco

O modelo de médias móveis (MA) é resultado da combinação de ruídos brancos do período atual e passados (WERNER; RIBEIRO, 2003). Assim, um modelo de médias móveis de ordem q ou MA(q) é dado pela Equação 3, descrita por Morettin e Tolo (2006).

$$\tilde{Z}_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_q \quad (3)$$

Em que:

θ_i = Parâmetros da estrutura de médias móveis, $i = 1, \dots, q$

ε_t = ruído branco

Algumas séries, de acordo com seu comportamento ao longo do tempo, podem ser modeladas de modo mais conveniente por meio da combinação de modelos (AR(p) e MA(q)), gerando um modelo denominado ARMA.

Morettin e Tolo (2006), descreve tal modelo de acordo com a Equação 4.

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (4)$$

Em que:

ϕ_i = parâmetros da estrutura autoregressiva, $i = 1, \dots, p$

θ_j = parâmetros da estrutura de médias móveis, $j = 1, \dots, q$

ε_t = ruído branco

Outra maneira de representar o modelo ARMA é conforme a Equação 5 (MORETTIN; TOLOI, 2006)

$$\phi(B)Z_t = \theta(B)\varepsilon_t \quad (5)$$

Em que:

B = operador de translação para o passado

$\phi(B)$ = operador auto-regressivo de ordem p

$\theta(B)$ = operador médias móveis de ordem q

ε_t = ruído branco

Segundo Morettin e Tolo (2006) a série será considerada ARIMA (p, d, q) quando poder ser expressa conforme a Equação 6.

$$\phi(B)\Delta^d Z_t = \theta(B)\varepsilon_t \quad (6)$$

Em que:

B = operador de translação para o passado

$\phi(B)$ = operador auto-regressivo de ordem p

$\theta(B)$ = operador médias móveis de ordem q

ε_t = ruído branco

d = número de diferenças

$\Delta = (1 - B)$ = representa o operador diferença

Para a Autoria de um modelo ARIMA, segue-se no geral a especificação de Box & Jenkins (2015), enumerada em três etapas:

- a) Identificação: Fase em que se determinam os valores de p, d e q . As funções de autocorrelação simples (FAS) e parciais (FAP) auxiliam nessa etapa.
- b) Estimação: após estimados os valores de p, d e q , os coeficientes do modelo

são obtidos por um algoritmo otimizador.

- c) Verificação: Essa etapa consiste em verificar se o modelo representa os dados adequadamente e se os resíduos representam um ruído branco.

3.2.1.3 SARIMA

Entende-se por sazonalidade como sendo a *tendência* do processo repetir certo tipo de comportamento a cada intervalo de tempo (SOUZA; CAMARGO 2004).

Espinosa, Prado e Ghellere (2010) descreve o modelo SARIMA como sendo o que possui uma parte sazonal (P, D, Q) e outra parte não sazonal (p, d, q). Desta forma, ele pode ser expresso pela Equação 7.

$$\varphi(B)\phi(B^s)(1 - B^s)^D(1 - B)^dZ_t = \theta(B)\theta(B^s)a_T \quad (7)$$

Em que:

B = operador de translação para o passado

$\varphi(B)$ = parte autorregressiva não sazonal ou estacionária de ordem p

$\phi(B^s)$ = parte autorregressiva sazonal de ordem P , e ordem sazonal s

$(1 - B^s)^D$ = parte de integração sazonal de ordem D e estação sazonal s

$(1 - B)^d$ = parte de integração não-sazonal de ordem d

$\theta(B)$ = parte não-sazonal de médias móveis de ordem q

$\theta(B^s)$ = parte sazonal de médias de ordem Q e estação sazonal de ordem s

3.2.1.4 SARIMAX

O método SARIMAX é derivado do SARIMA, em que nele é atribuído variáveis explicativas. É da ordem $(p, d, q) (P, D, Q) S (X)$, onde X é o vetor variáveis exógenas (CASAGRANDE et al., 2016). Esse modelo explica a variável dependente por meio de: variáveis exógenas; defasagens das variáveis exógenas e defasagens da variável

dependente (MOURA; MONTINI; CASTRO, 2011).

As variáveis exógenas podem ser modeladas por regressão linear múltipla, que é expressa conforme a Equação 8.

$$Y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \omega_t \quad (8)$$

Em que

$x_{k,t}$ = variáveis exógenas, $k=1, 2, \dots, k$

β_k = coeficiente de regressão, $k=1, 2, \dots, k$

ω_t = resíduo estocástico

Y_t = variável dependente

O coeficiente ω_t pode ser representado sob a forma do modelo ARIMA conforme a Equação 9.

$$\omega_t = \frac{\theta_q(B)\theta_Q(B^S)}{\phi_p(B)\phi_P(B^S)(1-B)^d(1-B^S)^D} \varepsilon_t \quad (9)$$

Substituindo ω_t descrito na equação 9 na equação 8, obtém-se a equação geral do modelo SARIMAX, conforme demonstrado na Equação 10.

$$Y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \left(\frac{\theta_q(B)\theta_Q(B^S)}{\phi_p(B)\phi_P(B^S)(1-B)^d(1-B^S)^D} \varepsilon_t \right) \quad (10)$$

O modelo SARIMAX é obtido seguindo etapas semelhantes ao do ARIMA, a diferença é que neste há uma etapa de introdução de variáveis exógenas (BOX; JENKINS; REINSEL, 2015; NASIRU; LUGUTERAH; ANZAGRA, 2013; SHUKLA; JHARKHARIA, 2013). As etapas são assim resumidas:

- a) Identificação do modelo
- b) Estimação dos parâmetros
- c) Diagnóstico de adequação do modelo
- d) Inclusão das variáveis exógenas
- e) Previsão e validação

3.3 VARIÁVEIS EXÓGENAS

De acordo com Marconi e Lakatos (2009) variáveis exógenas são variáveis que “influenciam, determinam ou afetam outra variável”. Rocha Junior (2011) cita algumas variáveis que podem interferir no consumo de energia elétrica, entre eles estão: economia, estabilidade política, fatores climáticos, crescimento demográfico, número de consumidores por classe e avanços tecnológicos.

Os subtópicos a seguir visam explicar as possíveis variáveis exógenas econômicas que podem interferir no comportamento da variável dependente do presente estudo.

3.3.1 Produto Interno Bruto (PIB)

O aumento do consumo de energia primária no Brasil acompanha de perto o crescimento do PIB e está diretamente ligado ao crescimento populacional e o desenvolvimento econômico. (ANEEL, 2008; GOLDEMBERG; LUCON 2008).

O PIB é a soma de tudo o que foi gerado em um país e é calculado a partir da quantidade de veículos, alimentos, vendas de serviços, estoques entre outros (BRASIL, 2016).

O PIB surgiu no final de 1930 nos Estados Unidos com a finalidade de justificar as políticas orçamentárias destinadas a tirar o EUA da depressão. Uma vez que era provável a entrada do país na Segunda Guerra Mundial, o governo usou o PIB para demonstrar que o envolvimento não comprometeria o padrão de vida da população e que a economia poderia fornecer suprimentos suficientes para combater a guerra (COSTANZA, 2009).

Klafke (2016) salienta que o PIB é considerado o melhor indicativo para mensurar a riqueza da população. À medida que o PIB per capita de um país aumenta, é notável que a população cresce financeiramente e vice-versa. Portanto, ele pode ser usado por investidores, juntamente com outros indicadores econômicos, como forma de analisar para quais países devem ser direcionados seus investimentos.

No âmbito de previsão de energia, Irffi et al. (2009) utilizaram o PIB como variável para prever a demanda do setor comercial e industrial da região Nordeste do Brasil e obtiveram resultados satisfatórios.

3.3.2 Índice de Atividade Econômica Regional (IBCR)

O Índice de Atividade Econômica Regional (IBCR) é um indicador mensal de atividade econômica das cinco regiões geográficas brasileiras. O IBCR é constituído por dados representativos do volume da produção da agropecuária, da indústria e do setor de serviços (BCB, 2017).

Fatores econômicos interferem nas previsões de energia, pois se a economia vai bem o consumo de energia tende a ser maior pois haverá mais produtos sendo produzidos e vice-versa (HAHN; NIEBERG; PICKL, 2009).

Neves e Vivas (2018) incrementaram a variável IBCR no método SVR com a finalidade de prever a demanda de energia do setor industrial das regiões norte, nordeste, centro-oeste, sul e sudeste, e obtiveram resultados satisfatórios.

3.3.3 Correlação de Variáveis

A análise de correlação mede o grau de associação entre duas variáveis. O modelo é denominado pelo coeficiente r , calculado matematicamente sem qualquer implicação de causa-efeito que pode orientar análises, conclusões e evidenciação na previsão (MONKS, 1987; MARTINS, 2002; MATOS, 2000).

3.3.3.1 Correlação de Pearson

Um dos métodos para calcular o grau de associação de variáveis é o coeficiente de correlação de produto de momentos de Pearson, ou, Correlação de Pearson. Ele

é representado por um número r , em módulo menor que um, e não dá prova de uma relação de causa-efeito, ou seja, não indica que uma variável tenha efeito direto ou indireto na outra. (MONKS, 1987; MARTINS, 2002).

De acordo com Figueiredo Filho e Júnior (2009), sua fórmula pode ser expressa segundo a Equação 11.

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - \bar{X}}{sx} \right) \left(\frac{y_i - \bar{Y}}{sy} \right) \quad (11)$$

Em que:

r = coeficiente de correlação de Pearson

n = número de elementos da amostra

x_i = i -ésima variável independente;

y_i = i -ésima variável dependente;

\bar{X} = média dos valores da variável independente;

\bar{Y} = média dos valores da variável dependente;

sx = desvio padrão em relação à variável independente;

sy = desvio padrão em relação à variável dependente.

O coeficiente r varia de -1 a +1, de modo que quanto mais perto dos extremos este coeficiente se encontra maior é a evidência de correlação entre as variáveis. Se o resultado for 0, significa que não existe correlação (FIGUEIREDO FILHO; JUNIOR, 2009). Shimakura (2006) classifica o coeficiente r conforme o Tabela 1.

Tabela 1: Classificação do coeficiente de Pearson

Correlação	Varição Positiva	Varição Negativa
Bem fraca	+0 a +0,19	-0 a -0,19
Fraca	+0,2 a +0,39	-0,2 a -0,39
Moderada	+0,4 a +0,69	-0,4 a -0,69
Forte	+0,7 a +0,89	-0,7 a -0,89
Muito Forte	+0,90 a 1	-0,90 a -1

Fonte: Adaptado de Shimakura (2006)

Correlação negativa quer dizer que os altos valores das variáveis x estão relacionados a baixos valores de y e baixos valores de x se relacionam com altos valores de y . Para correlação positiva os valores das variáveis x e y se relacionam proporcionalmente (DANCEY; REIDY, 2006).

3.4 CRITÉRIO DE INFORMAÇÃO DE AKAIKE (AIC)

A escolha do modelo apropriado, do ponto de vista estatístico, é um tópico extremamente importante na análise de dados (Bozdangan, 1987). Neste sentido, definir o critério de seleção do modelo e realizar análise dos erros contribui para a escolha de um modelo mais acurado.

O critério de seleção utilizado para determinar o melhor modelo é o de Akaike. O critério de informação de Akaike (AIC) avalia a qualidade do ajuste do modelo paramétrico, através do método de máxima verossimilhança e segundo este critério o melhor modelo será o que apresentar o menor valor de AIC (AKAIKE, 1974).

3.5 MEDIDAS DE ACURÁCIA

Acurácia é o grau de precisão de uma estimativa para seu parâmetro. O indicador utilizado para medir o desempenho e acurácia da previsão é chamado de erro, quanto menor for esse valor, mais preciso será a sua previsão, logo mais aceita (DOYLE; FENWICK, 1976).

De acordo com Campos (2008) os métodos mais utilizados na análise de resíduo, a fim de comparar a série original com a previsão são: erro médio (ME); erro absoluto médio (MAE); erro quadrático médio (MSE); erro percentual absoluto médio (MAPE); e raiz do erro quadrático médio (RMSE). As equações destes métodos estão descritas a seguir:

a) Erro Médio (ME)

$$\frac{1}{n} \sum_{i=1}^n Y_i - \hat{Y}_i \quad (12)$$

b) Erro Absoluto Médio (MAE)

$$\frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (13)$$

c) Erro Quadrático Médio (MSE)

$$\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (14)$$

d) Erro Percentual absoluto Médio (MAPE)

$$\frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (15)$$

e) Raiz do Erro Quadrático Médio (RMSE)

$$\left(\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \right)^{1/2} \quad (16)$$

Em que:

Y_i = Valor observado

\hat{Y}_i = Valor previsto

n = Número de observações

3.6 TRABALHOS RELACIONADOS

Moura (2011) realizou um estudo de projeção do consumo da energia elétrica brasileira nos setores comercial, industrial e residencial utilizando o modelo sazonal autorregressivo de médias móveis com variáveis exógenas (SARMAX). Foi utilizado série temporal do período de janeiro de 2003 a setembro de 2010 para gerar previsões mensais de outubro de 2010 a fevereiro de 2011. Para cada setor realizou-se testes com quatro variáveis e verificado a existência de correlação entre a variável independente e dependente. Concluiu-se que incluir variáveis independentes que atenderam o pressuposto de correlação no modelo SARMAX apresentaram resultados satisfatórios.

Mendiondo e Oliveira (2014) realizaram um estudo com o objetivo de avaliar se os modelos baseados em redes neurais (RNA) apresentam maior eficiência quando comparados a métodos de regressão na previsão de demanda de energia elétrica. Os dados utilizados foram obtidos das comunidades do Vale do Ribeira – SP, Pedra Branca (PE), Vera Cruz (PA), da comunidade da Praia Vermelha, Ilha Grande – RJ e uma amostra de quinze domicílios urbanos, com a finalidade de avaliar a capacidade de generalização dos modelos. Os melhores resultados em ambos os modelos, surgiu quando oito características das famílias foram incrementadas como variável. O resultado foi que as RNA tiveram maior eficiência que os modelos de regressão para esta aplicabilidade.

Pereira, Almeida e Velloso (2015) apresentaram um estudo comparativo dos métodos SARIMAX e lógica *fuzzy* para prever a demanda de energia para o estado da Bahia. As seguintes variáveis exógenas foram utilizadas: número de unidades consumidoras, temperatura e precipitação da chuva. O método lógica *fuzzy* apresentou resultados superiores para todas as possíveis combinações de variáveis, quando comparado o método SARIMAX.

Aleixo (2015) aplicou conceitos de planejamento energético encontrados na literatura com a finalidade de realizar uma simulação de projeção de demanda de energia elétrica para o município de Londrina - PR, com horizonte de vinte anos. Para esse estudo foi utilizado a metodologia LEAP - *Long Range Energy Alternatives Planning System* e criados seis cenários de estudo (quatro cenários Referência e dois Alternativos), considerando diferenças econômicas, tecnológicas e premissas de

evolução de progressão de eficiência energética. O resultado foi que dois dos cenários de referência (tendência histórica e pessimista) se destacaram dos demais.

Coelho Junior et al. (2018) realizaram uma projeção de consumo de energia elétrica do nordeste brasileiro para o ano de 2013 utilizando dados de janeiro de 2004 a dezembro de 2012. A metodologia utilizada foi a Box e Jenkins, para os modelos da família ARIMA. Como resultado obtiveram que o modelo SARIMA(1,1,0)(0,0,1) forneceram os melhores resultados.

Neves e Vivas (2018) apresentaram um estudo comparativo dos modelos SARIMA, *holt winters*, regressão linear com erros SARIMA, decomposição com variáveis *dummies*, decomposição com Série de *Fourier*, *Randon forest* e SVR, aplicados para prever a demanda de energia elétrica do setor industrial de cada região do Brasil (centro-oeste, norte, nordeste, sul e sudeste). Como resultado obtiveram ampla predominância dos modelos *machine learning* entre os melhores modelos, em especial o SVR que apareceu como um dos melhores em 4 dos 5 modelos. Além disso, nenhum modelo que utilizou apenas a própria variável dependente conseguiu resultados tão expressivos.

Gross et al. (2018) elaboraram um artigo com o objetivo de estimar as relações de curto e longo prazo da demanda de energia para o setor industrial no Brasil. Os autores utilizaram o Modelo de Auto Regressão Vetorial com correção de erro (VECM) e método de Cointegração de Johansen, para determinar as elasticidades renda, preço da demanda e preço cruzado por energia elétrica. A metodologia Box-Jenkins projetou a demanda para os meses de junho a agosto do ano de 2012. O modelo ARIMA obteve uma aproximação de 97,46% (em relação aos valores reais?) de modo que foi concluído que os modelos de Box e Jenkins tiveram bons resultados para dados mensais em previsões de curto prazo.

Mohammed (2018) utilizou os métodos Regressão Logarítmica e RNA para prever a demanda de energia do Iraque a longo prazo e comparar com outros estudos sobre o sistema de energia do país. Nos modelos ele incrementa as variáveis: população, PIB, índice de preços aos consumidores e temperatura. A conclusão foi que o modelo logarítmico linear é mais apropriado que o método RNA neste estudo de caso, pois tem maior flexibilidade para atualizar os dados e é mais representativo para os dados pobres após processá-los.

Wang, Li e Li (2018) utilizaram métodos de previsões lineares, híbridas-lineares e não-lineares para prever a demanda de energia da China e Índia utilizando dados

de 1990 a 2016, para realizar previsão de longo prazo para 2017 a 2026. Os autores concluíram que os resultados foram satisfatórios para os países que realizaram a previsão, podendo assim, os métodos serem aplicados para outras regiões. Além de que o crescimento da taxa de consumo de energia da Índia será de 2 a 4 vezes a taxa da China de 2017 a 2026, indicando que Índia se tornará ainda mais importante no mercado global de energia

4 MATERIAIS E MÉTODOS

Este tópico apresenta aspectos metodológicos e os materiais utilizados no trabalho. São descritos a classificação e etapas da pesquisa, onde foram obtidos os dados e quais software utilizados.

4.1 CLASSIFICAÇÃO DA PESQUISA

Gil (2010) define pesquisa como procedimento racional e sistemático com a finalidade de oferecer respostas a problemas propostos.

Para Marconi e Lakatos (2009) pesquisa é um procedimento formal com metodologia que necessita de conhecimento científico para chegar a um resultado que representa a realidade ou para descobrir verdades parciais.

De acordo com Kauark, Manhães e Medeiros (2010) a pesquisa pode ser classificada de acordo com a natureza, abordagem (assunto), propósito (objetivo), e do procedimento utilizado para alcançar os dados (meios).

A Figura 5 apresenta de forma geral, as classificações da pesquisa. As características abordadas neste trabalho, encontram-se em destaque.

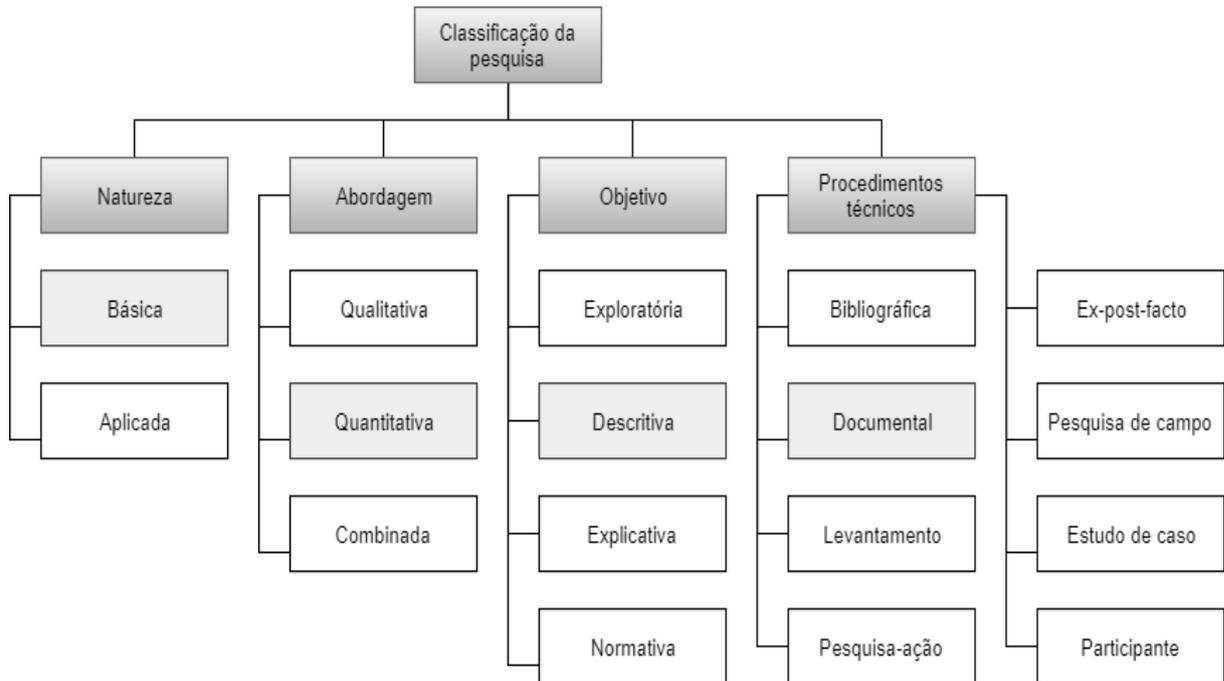


Figura 5: Classificação da pesquisa
Fonte: Autoria própria (2019)

Do ponto de vista da natureza a pesquisa será classificada como básica pura, pois teve como objetivo prever a demanda de energia do setor industrial de duas regiões específicas e os resultados obtidos não serão aplicados. Está de acordo com Gil (2010) que define pesquisa básica como sendo a que objetiva desenvolver novos conhecimentos sem ter uma preocupação de aplicação prática dos resultados.

Quanto a abordagem a pesquisa é classificada como quantitativa, pois os dados serão quantificáveis e receberão tratamento estatístico (TURRIONI; MELLO, 2012).

No que se refere a objetivo a pesquisa será classificada como descritiva, pois os dados serão analisados sem que haja uma manipulação. Portanto, ajusta-se a definição de Prodanov e Freitas (2013) que descreve pesquisa descritiva como as que objetivam estudar fatos, variáveis, fenômenos sem que haja interferência nos dados.

Os dados serão coletados através de relatórios anuais da Empresa de Pesquisa Energética (EPE), portanto, a classificação de procedimentos técnicos é pesquisa documental. Na definição de Marconi e Lakatos (2009) pesquisa documental é a que os dados são coletados de documentos, escritos ou não.

4.2 MATERIAIS

Este tópico apresenta os materiais utilizados na pesquisa, como a série de dados da região sudeste, região sul, PIB e IBCR.

4.2.1 Série de dados da Região Sudeste

Os dados da região Sudeste também foram obtidos através do site SGS – Sistema Gerenciador de Séries Temporais. O período observado é de janeiro de 2002 a junho de 2018 e possui 198 observações. A Gráfico 1 representa os dados graficamente.

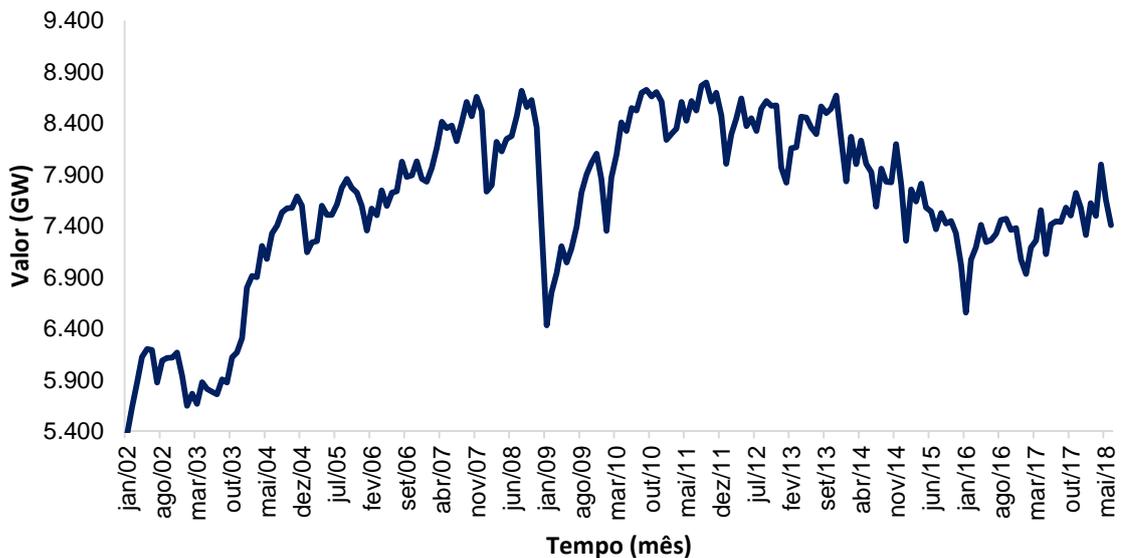


Gráfico 1: Série de dados de energia consumida pelo setor industrial na região Sudeste
Fonte: Autoria Própria (2019)

O Gráfico 2 apresenta a distribuição de frequência do consumo de energia na região Sudeste.

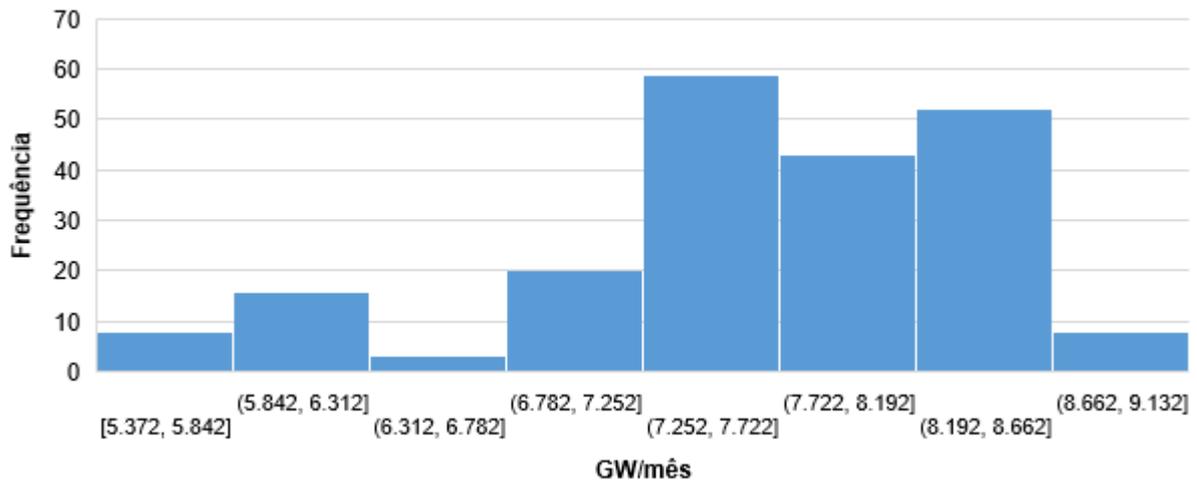


Gráfico 2: Distribuição de frequência do consumo de energia do setor industrial na região Sudeste

Fonte: Autoria Própria (2019)

Gráfico 2: Distribuição de frequência do consumo de energia do setor industrial na região Sudeste
Autor: Autoria própria (2019)

As características dos dados como média, mediana, ponto de máximo e mínimo, desvio padrão, assimetria e curtose pode ser verificado na Tabela 2.

Tabela 2: Característica da série de dados de energia da região Sudeste

Series: SUDESTE	
Observações	198
Média	7628.57
Mediana	7723,000
Máximo	8796,000
Mínimo	5372,000
Desvio Padrão	813,263
Assimetria	-0,8451
Curtose	3,101

Fonte: Autoria Própria (2019)

Os dados possuem média de 7628,57GW, mediana 7773GW, ponto de máximo de 8796GW, mínimo de 5372GW e um desvio padrão de 813,26GW. A distribuição de frequência possui uma assimetria negativa de -0,8451, o qual significa que possui uma “cauda” levemente alongada para a esquerda.

4.2.2 Série de Dados Região Sul

A série temporal do consumo de energia industrial da região Sul foi obtida através do site do SGS, do Banco Central do Brasil.

Foram realizadas 198 observações no período de janeiro de 2002 a junho de 2018. O Gráfico 3 apresenta a demonstração gráfica da série.

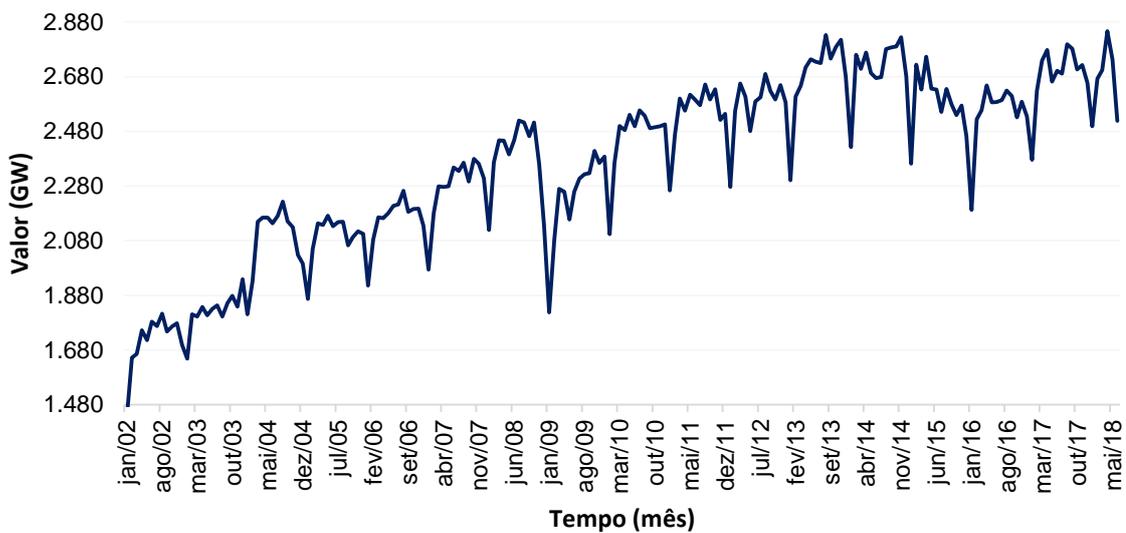


Gráfico 3: Consumo de energia mensal do setor industrial da região Sul
Fonte: Autoria Própria (2019)

A série possui características sazonal com um período de 12 meses, onde o mínimo acontece sempre no mês de janeiro. O Gráfico 4 mostra a distribuição de frequência da série.

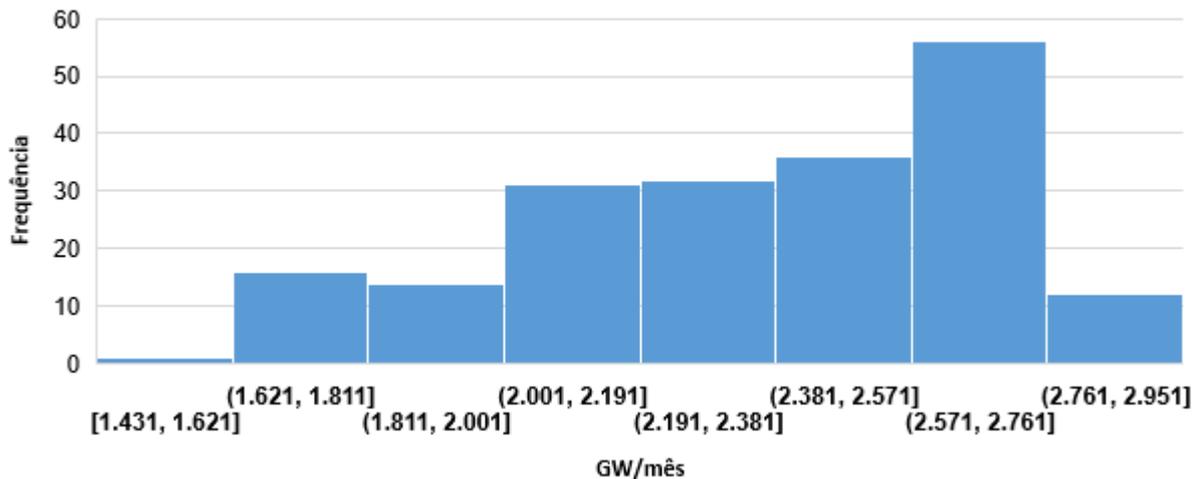


Gráfico 4: Distribuição de frequência do consumo de energia do setor industrial na região Sul
Fonte: Autoria Própria (2019)

E suas características, como: média, mediana, pontos de máximo e mínimo, desvio padrão, assimetria e curtose estão demonstradas na Tabela 3.

Tabela 3: Característica da série de dados de energia da região Sudeste

Series: SUL	
Observações	198
Média	2.361,500
Mediana	2.446,500
Máximo	2.847,000
Mínimo	1.431,000
Desvio Padrão	319,710
Assimetria	0,6070
Curtose	2,434

Fonte: Autoria Própria (2019)

Os dados possuem média de 2361,50GW e um valor máximo de 2446,50GW e um mínimo de 1431GW, tendo um desvio padrão de 319,71GW. Sua assimetria é negativa e isso significa que a curva de frequência possui uma “cauda” a esquerda do ponto máximo maior que quando comparado a da direita.

4.2.3 Série de dados do PIB

Os valores do PIB são obtidos trimestralmente no site SGS. A série possui 67 observações e como os meses janeiro e fevereiro de 2002 não possuía valores, foi necessário utilizar a partir de dezembro de 2001.

O Gráfico 5 contém a demonstração gráfica dos dados.

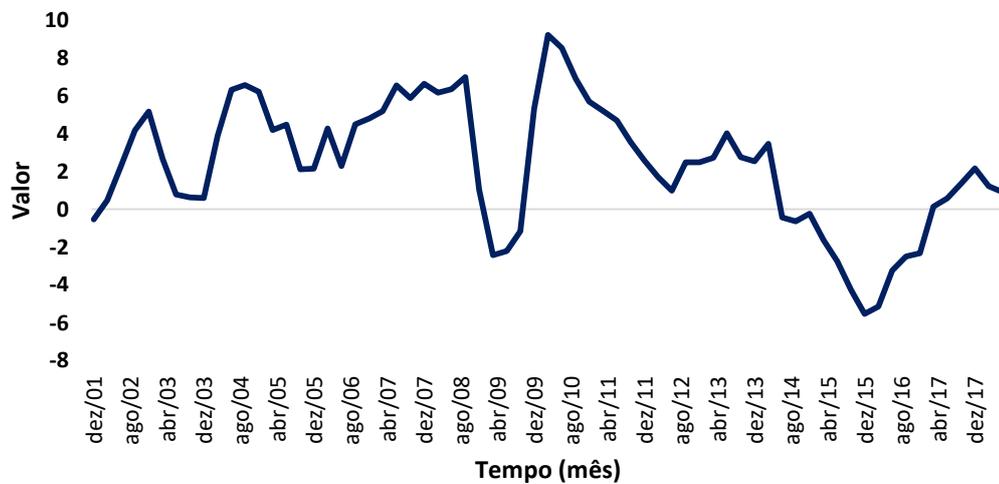


Gráfico 5: Série de dados PIB – Brasil
Fonte: Autoria Própria (2019)

A distribuição de frequência dos dados está apresentada no Gráfico 6.

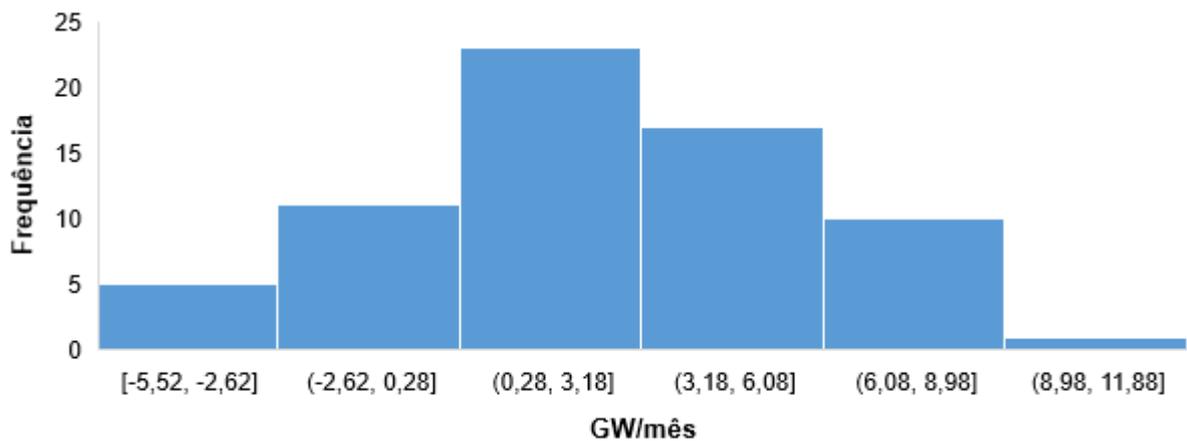


Gráfico 6: Distribuição de frequência do PIB brasileiro
Fonte: Autoria Própria (2019)

As estatísticas básicas da série como: média, mediana, máximo e mínimo padrão, assimetria e curtose podem ser verificadas na Tabela 4.

Tabela 4: Distribuição de frequência da série de dados PIB

Serie: PIB	
Observações	67
Média	2,381
Mediana	2,490
Máximo	9,210
Mínimo	-5,520
Desvio Padrão	3,334
Assimetria	0,313
Curtose	2,551

Fonte: Autoria Própria (2019)

Uma das características da série é possuir assimetria negativa de -0,313355, este coeficiente significa que a distribuição de frequência possui uma “cauda” levemente alongada para a esquerda. Os dados possuem média de 2.380746, mediana 2.49, ponto de máximo de 9.21, mínimo de -5.52 e um desvio padrão de 3.334063.

Os coeficientes de correlação da variável PIB com a série de energia sul e sudeste foram calculados, e seus respectivos resultados estão apresentados na Tabela 5.

Tabela 5: Correlação da variável PIB

PIB	Coefficiente
SUL	-0,17
SUDESTE	0,37

Fonte: Autoria Própria (2019)

A região sul apresentou baixo poder explicativo, visto que seu coeficiente de correlação ficou baixo. A região sudeste também apresentou baixa correlação.

4.2.4 Série de dados IBCR – Sudeste

Assim como o da região Sul, os dados do IBCR Sudeste também foram obtidos

através do site SGS. Foram feitas 198 observações no período de janeiro de 2002 a junho de 2018. O Gráfico 7 representa o gráfico da série de dados.

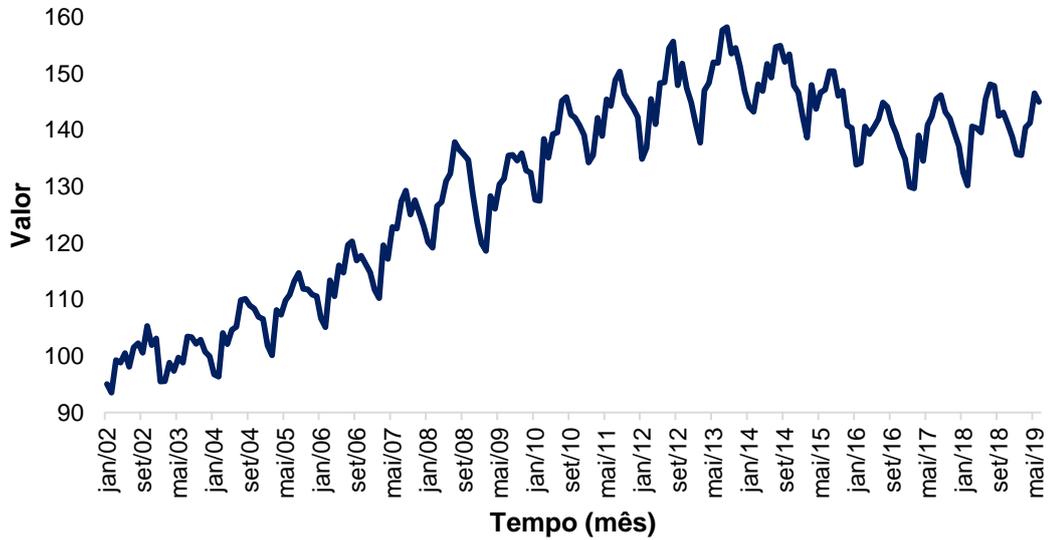


Gráfico 7: Série de dados do IBCR da região Sudeste
Fonte: Autoria Própria (2019)

A série possui característica sazonal com um período de 12 meses no qual os valores mínimos representam os meses de fevereiro e máximos em julho e agosto.

O Gráfico 8 apresenta a distribuição de frequência da série.

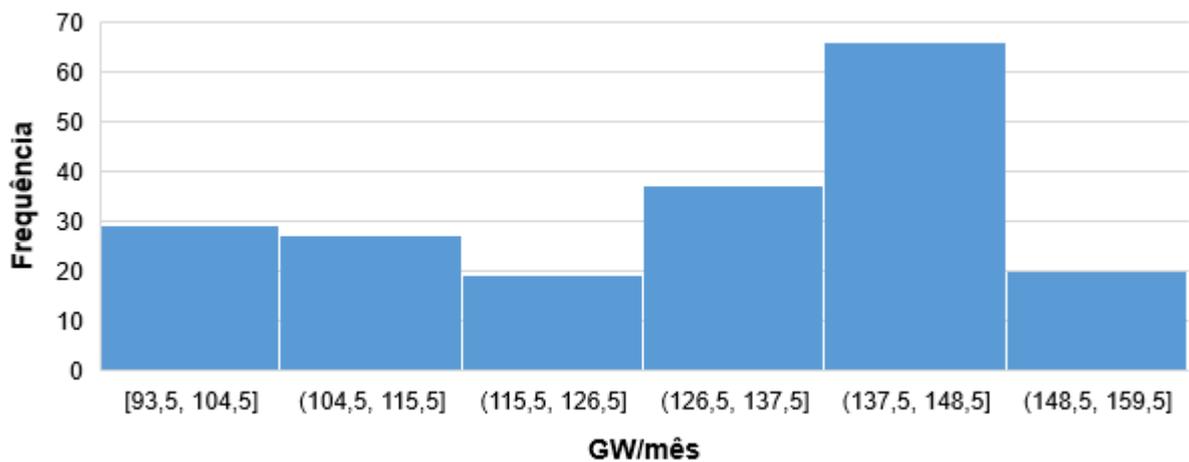


Gráfico 8: Distribuição de frequência da série de dados IBCR Sudeste
Fonte: Autoria Própria (2019)

As características da série estão apresentadas na Tabela 6.

Tabela 6: Características da série de dados IBCR Sudeste

Série: IBCR SUDESTE	
Observações	198
Média	129,0982
Mediana	134,645
Máximo	158,200
Mínimo	93,500
Desvio Padrão	17,921
Assimetria	-0,422
Curtose	1,8530

Fonte: Autoria Própria (2019)

A série possui assimetria negativa, e assim, uma “cauda” alongada a esquerda maior que a da direita. A média é de 129,0982, mediana 134,6450, ponto de máximo 158,2 e mínimo 93,5 e um desvio padrão médio de 17,92125.

O IBCR da região sudeste apresenta correlação moderada com a série de dados de energia, com um coeficiente de 0,67.

4.2.5 Série de dados IBCR – Sul

Os dados do IBCR foram obtidos mensalmente no site SGS cujo endereço eletrônico é:

Foram feitas 198 observações no período de janeiro de 2002 a junho de 2018. Sua representação gráfica está demonstrada no gráfico abaixo:

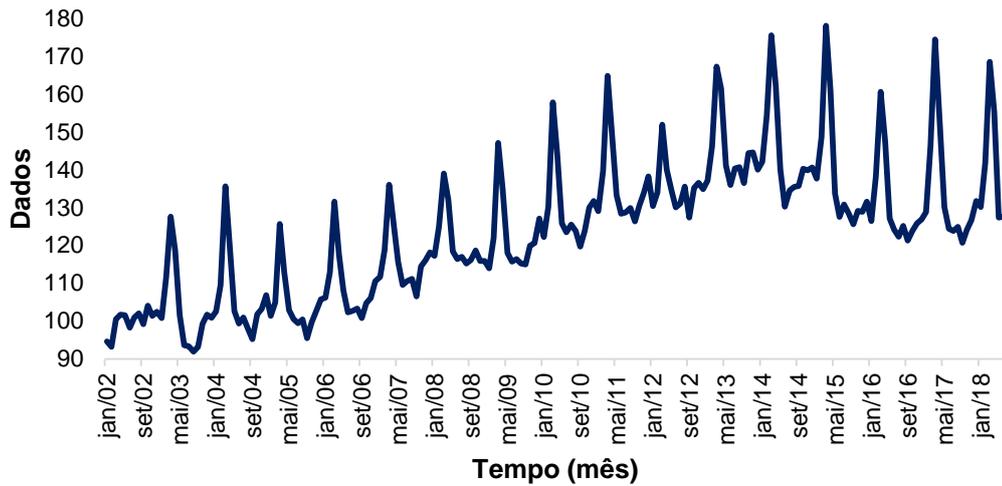


Gráfico 9: Série de dados IBCR região Sul
Fonte: Autoria própria (2019)

A série possui características sazonais com um período de 12 meses onde o ponto máximo é atingido no mês de março e o mínimo em setembro. O Gráfico 10 apresenta a distribuição de frequência dos dados.

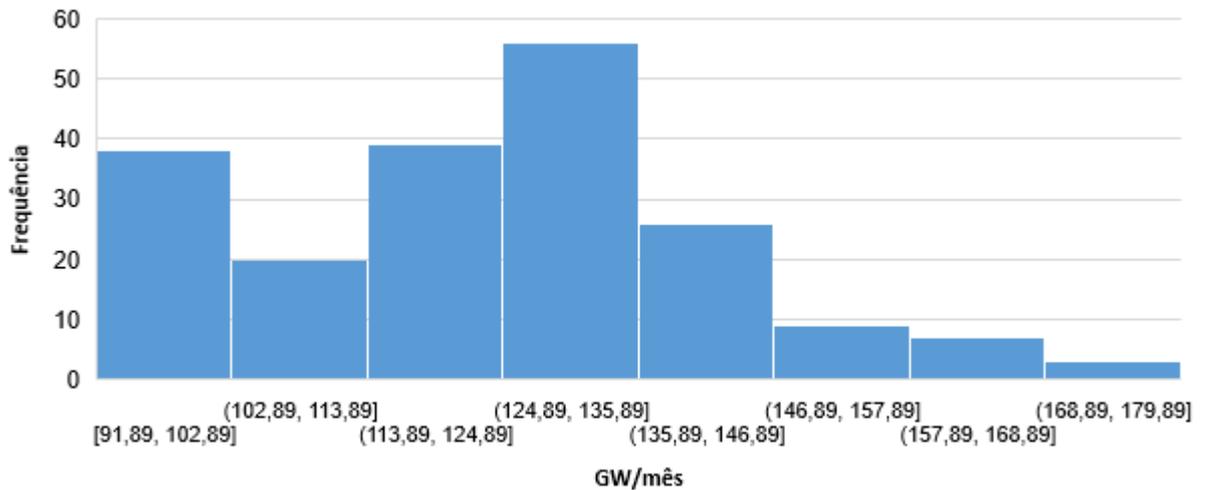


Gráfico 10: Distribuição de frequência da série de dados IBCR Sudeste
Fonte: Autoria Própria (2019)

A Tabela 7 apresenta as características da série

Tabela 7: Características da série de dados IBCR Sudeste

Série: IBCR SUL	
Observações	198

Média	123,9643
Mediana	125,060
Máximo	178,130
Mínimo	91,890
Desvio Padrão	18,271
Assimetria	0,443
Curtose	2,9918

Fonte: Autoria Própria (2019)

A série de dados possui média de 123.9643, mediana de 125.06, valor máximo de 178.173 e mínimo de 91.89, tendo um desvio padrão de 18.27065. Sua assimetria é positiva e isso significa que a curva de frequência possui uma “cauda” a direita do ponto máximo mais alongada que a esquerda.

O IBCR Sul apresentou coeficiente de correlação de 0,76, isso significa que possui uma correlação forte com a série de energia.

4.3 MÉTODOS

As etapas das modelagens das séries estão descritas na Figura 6.

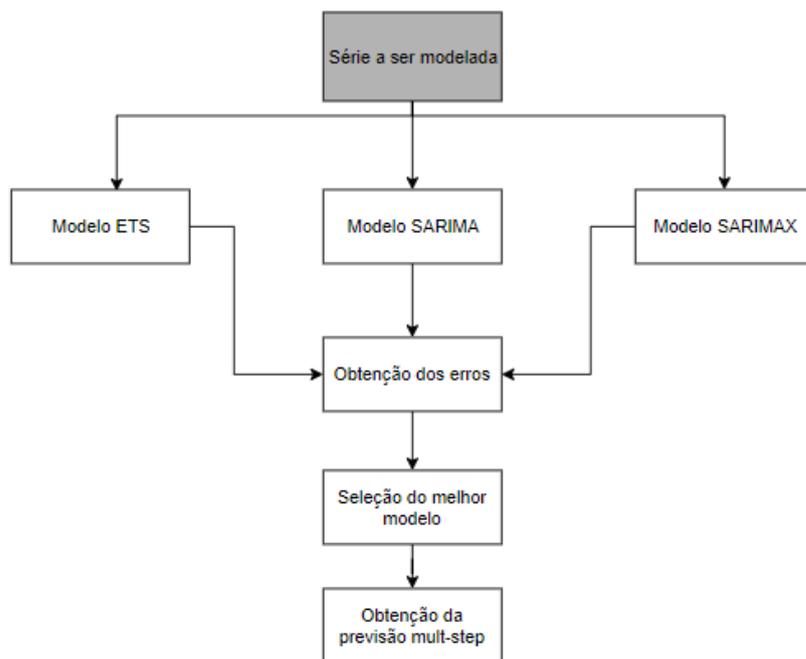


Figura 6: Etapas da pesquisa
Fonte: Autoria própria (2019)

Para cada série foi realizado cinco modelagens, em que três delas foram incrementadas variáveis exógenas. Em seguida, foram calculadas as medidas de acurácia, MAPE e MAE, e realizado um comparativo entre os coeficientes dos erros para verificar qual modelo apresentou melhor resultado.

O software utilizado na modelagem foi o Eviews 10 e para plotagem do gráfico e cálculo de erros foi o Excel.

Os tópicos seguintes apresentam as etapas de Autoria de cada método.

4.3.1 Método ETS

Para realizar a modelagem deste método foi aplicado o modo automático do software Eviews, onde nele é testado vários modelos e apontado o que obteve melhor resultado para o critério de seleção escolhido. O critério de seleção utilizado para comparar os modelos simulados é o de Akaike (AIC). A modelagem seguiu as seguintes etapas:

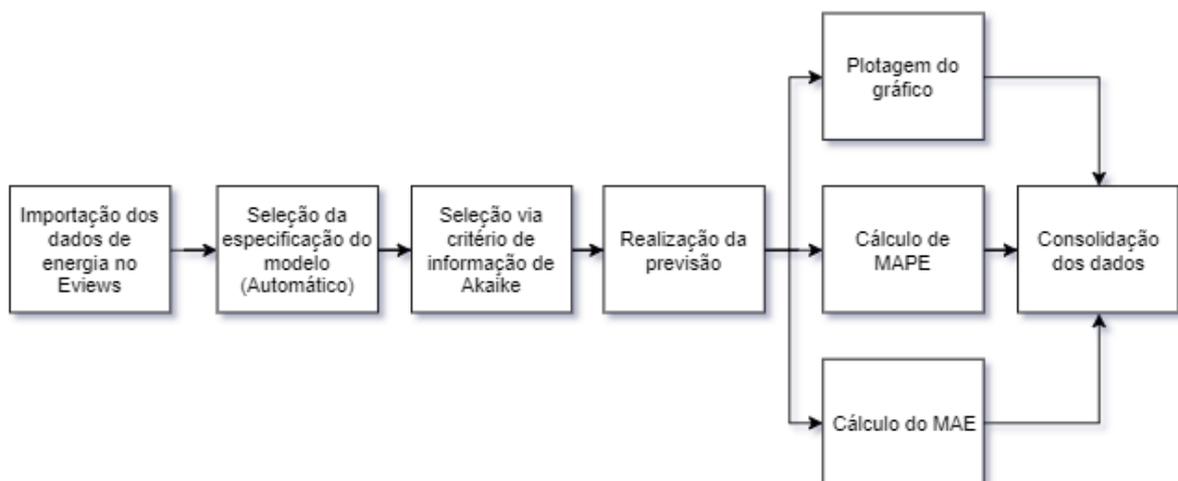


Figura 7: Fluxograma de previsão do modelo ETS

Fonte: Autoria Própria (2019)

No primeiro momento foi realizado a importação dos dados do software Excel

para o Eviews 10. Após a importação, foi realizado a seleção das especificações do modelo, em que o erro, tendência e sazonalidade seria escolhido de modo automático e o método de seleção seria o critério de Akaike, e assim, a previsão pode ser realizada.

Por último foi realizado a plotagem do gráfico e cálculo das medidas MAPE e MAE. Por último foi feito a consolidação dos dados, para melhor organização da pesquisa.

4.3.2 Método SARIMA

Para encontrar o modelo SARIMA, foi utilizado a função “automatic ARIMA forecasting”. A escolha do melhor método foi feita através do Critério de Informação de Akaike. A Figura 8 apresenta o fluxograma de previsão com o modelo SARIMA.

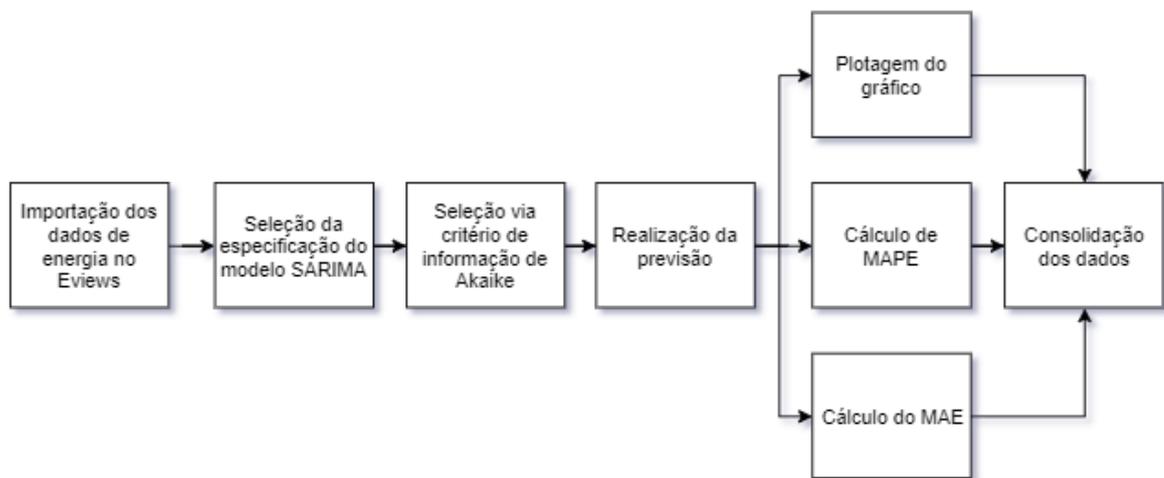


Figura 8: Fluxograma de previsão do modelo SARIMA
 Fonte: Autoria Própria (2019)

A primeira etapa consiste em importar os dados de energia do Excel para o Eviews, em seguida é feito a seleção do modelo e do critério de informação. Após realizada a previsão é feita a plotagem do gráfico e cálculo de erros e consolidado todas as informações no Excel.

4.3.3 Método SARIMAX

Para a modelagem do método SARIMAX, seguiu-se duas etapas. Primeiramente foi realizado a previsão das variáveis PIB e IBCR, e em seguida realizado a modelagem da série pelo método.

4.3.3.1 Modelagem variável PIB

O fluxograma das etapas da Autoria da previsão da variável PIB pode ser verificado na Figura 9.

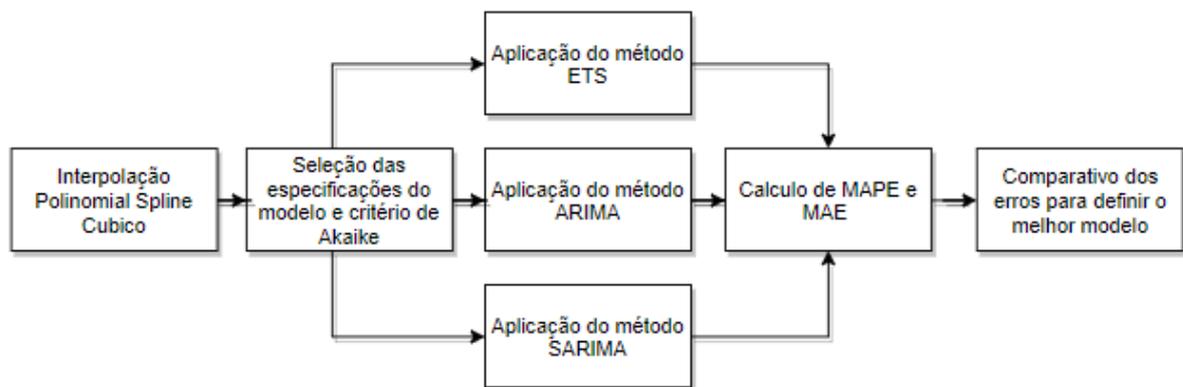


Figura 9: Fluxograma da previsão da série de dados PIB
Fonte: Autoria Própria (2019)

Como os dados da variável são trimestrais, fez-se necessário realizar uma interpolação dos dados, a fim de torná-los mensais. Utilizou-se como metodologia a Interpolação Polinomial por Splines Cúbicas, com auxílio do software Eviews 10.

Após a realização da interpolação, foi utilizado o critério de Akaike e a função automática do Eviews para encontrar os modelos com melhores ajustes à série dos métodos ETS, ARIMA e SARIMA. Em seguida foram calculados os erros e realizado a comparação entre os modelos testados.

4.3.3.2 Modelagem da variável IBCR

Para incrementar a variável ao modelo SARIMAX primeiramente foi necessário fazer a previsão dos valores do IBCR de julho de 2018 a junho de 2019, as etapas seguidas estão apresentadas na Figura 10.

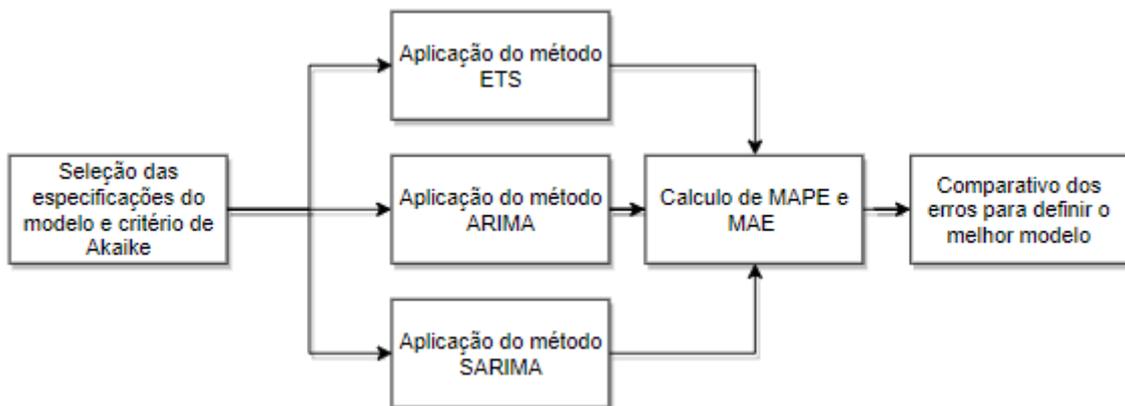


Figura 10: Etapas da previsão da série de dados da variável IBCR
 Fonte: Autoria Própria (2019)

Os métodos ETS, ARIMA e SARIMA foram aplicados utilizando o modo automático do software Eviews e o critério de seleção de Akaike. Em seguida foi realizado o cálculo das medidas de acurácia e realizado um comparativo entre elas.

4.3.3.3 Modelagem SARIMAX

Na simulação do método SARIMAX também foi utilizada a função automática do Eviews, combinado com o critério de informação de Akaike. As etapas de Autoria do método podem ser verificadas na Figura 11.

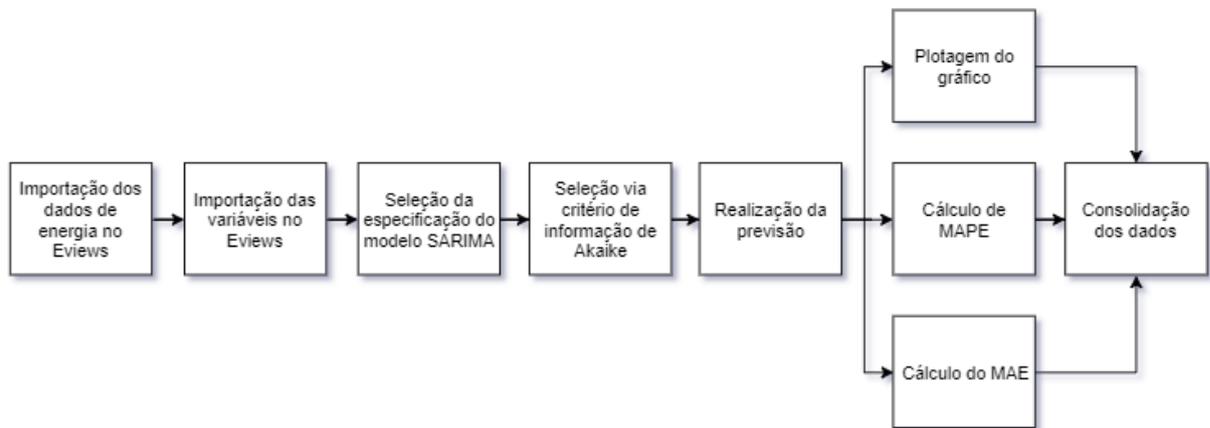


Figura 11: Fluxograma de previsão do modelo SARIMAX
Fonte: Autoria Própria (2019)

Primeiramente foi realizada a importação dos dados de energia e da variável que será incrementada ao modelo. Em seguida realizado as especificações do modelo e seleção do critério de informação de Akaike. Após obtido os resultados da previsão foi feito a plotagem do gráfico, cálculo das medidas de acurácia e consolidação dos dados

5 RESULTADOS

Neste capítulo são apresentados os resultados das previsões dos modelos de ETS, SARIMA e SARIMAX.1. Após as simulações, fez-se um comparativo entre os métodos e por fim, apresentado o que obtiver o melhor resultado.

5.1 REGIÃO SUDESTE

5.1.1 ETS (Error, Trend, Season)

Para a região sudeste, o modelo ETS que apresentou o melhor ajuste foi o modelo ETS(A,M,M), que possui erros aditivos, tendência e sazonalidade multiplicativa. Sua equação é apresentada abaixo:

$$\mu_t = l_{t-1}b_{t-1}s_{t-m} \quad (17)$$

$$l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t/s_{t-m} \quad (18)$$

$$b_t = b_{t-1} + \beta\varepsilon_t/(s_{t-m}l_{t-1}) \quad (19)$$

$$s_t = s_{t-m} + \gamma\varepsilon_t/l_{t-1}b_{t-1} \quad (20)$$

Em que:

l_t = Estimativa de nível, $t = 1,2,3 \dots m$

b_t = Estimativa de tendência, $t = 1,2,3 \dots m$

s_t = Estimativa de sazonalidade, $t = 1,2,3 \dots m$

α = Parâmetro de estimação para nível

β = Parâmetro de estimação para tendência

γ = Parâmetro de estimação para sazonalidade

ε_t = Ruído branco

O critério de Akaike do modelo apresentaram o menor valor, e logo, o que melhor se ajusta. O comparativo entre os principais modelos está demonstrado na

Tabela 8.

Tabela 8:Comparativo de AIC dos modelos ETS				
Model	Compact LL	Likelihood	AIC*	BIC
A,M,M	-1531,09	-1288,5	3094,18	3146,8
A,N,A	-1534,54	-1291,95	3097,08	3143,11
A,M,A	-1534,44	-1291,86	3100,89	3153,5
A,AD,A	-1534,11	-1291,52	3102,22	3158,12
A,MD,A	-1534,13	-1291,54	3102,25	3158,15
M,N,M	-1538,97	-1296,38	3105,95	3151,98
M,M,M	-1538,48	-1295,89	3108,95	3161,57
M,MD,M	-1537,56	-1294,97	3109,12	3165,02
M,N,A	-1543,41	-1300,82	3114,81	3160,85
M,A,A	-1542,66	-1300,08	3117,33	3169,94

Fonte: Autoria Própria (2019)

O Gráfico 11 apresenta os valores utilizados para ajuste em azul e em vermelhos os valores previstos pelo modelo ETS(A, M, M)

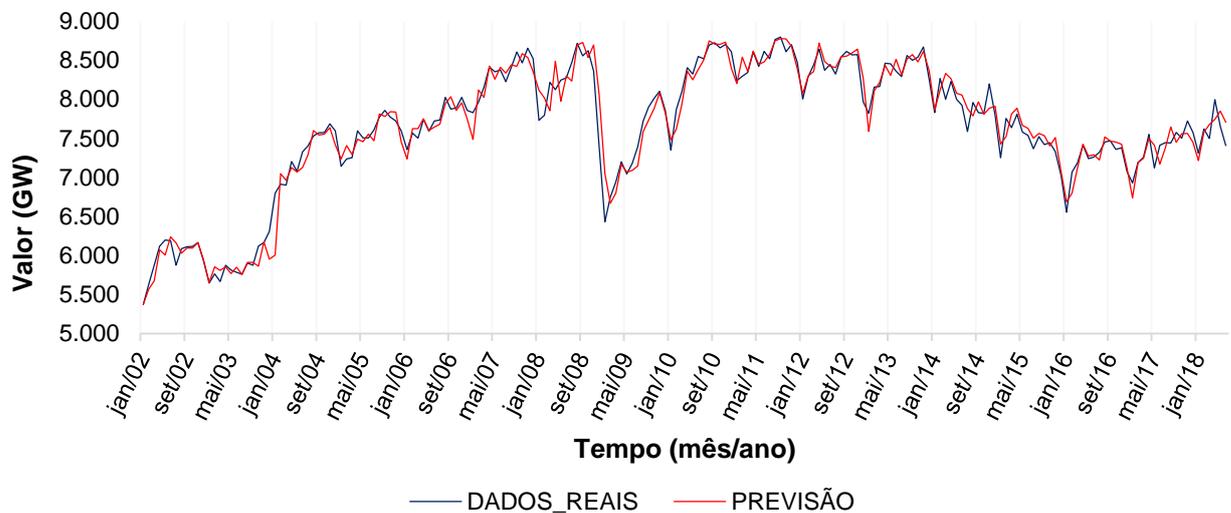


Gráfico 11: Gráfico dos dados reais e da previsão obtida através do método ETS - Região Sudeste

Fonte: Autoria Própria (2019)

As medidas de acurácia para estes valores foram calculadas e podem ser verificadas na Tabela 3, o erro médio da previsão dentro da amostra é de 1,53% tendo assim, um desvio médio de 114,9GW.

Tabela 9: Medidas de acurácia da previsão da região Sudeste via modelo ETS

Medida	Valor
MAPE	1,49%
MAE	115,5

Fonte: Autoria própria (2019)

5.1.2 SARIMA

Para o segundo método testado, o modelo que obteve melhores resultados foi o SARMA (4,4)(1,2)[12]. Os coeficientes da equação do modelo SARMA (4,0,4)(1,0,2)[12] estão apresentados na Tabela 10.

Tabela 10: Coeficientes da equação do modelo SARIMA (4,0,4)(1,0,2)

Parâmetro	Coefficiente
C	0,002
AR(1)	0,465
AR(2)	0,964
AR(3)	0,423
AR(4)	0,939
SAR(12)	0,994
MA(1)	0,409
MA(2)	-1,117
MA(3)	0,409
MA(4)	1,000
SMA(12)	0,588
SMA(24)	0,290

Fonte: Autoria Própria (2019)

O comparativo de AIC entre os principais modelos testado pelo software, é apresentado na Tabela 11

Tabela 11: Comparativos de AIC dos principais modelos SARIMA testados

Modelo	AIC*
(4,4)(1,2)	-4,5243
(4,4)(2,2)	-4,5187
(0,0)(1,2)	-4,5121
(3,3)(2,2)	-4,5116

(0,0)(1,1)	-4,5103
(0,0)(2,1)	-4,5097
(3,2)(1,2)	-4,5090
(2,3)(1,2)	-4,5086
(0,0)(2,2)	-4,5079
(3,2)(2,2)	-4,5068

Fonte: Autoria Própria (2019)

O gráfico da série é representado pelo Gráfico 12, onde a linha azul representa os dados da série e a linha vermelha a previsão.

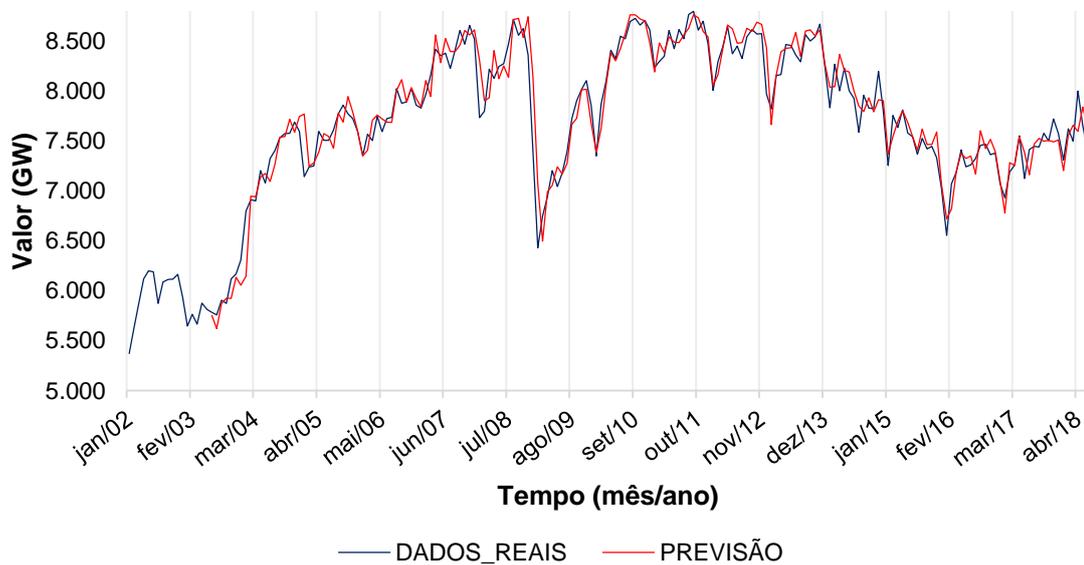


Gráfico 12: Gráfico dos dados reais e da previsão obtida através do método SARIMA – Região Sudeste

Fonte: Autoria própria (2019)

As medidas de acurácia foram calculadas levando em consideração os dados dentro da amostra, e podem ser verificados na tabela abaixo.

Tabela 12: Medidas de acurácia da previsão via modelo SARIMA para região sudeste

SUDESTE	MAPE	MAE
SARIMA	1,56%	120,5

Fonte: Autoria própria (2019)

5.1.3 SARIMAX com variável PIB

5.1.3.1 Modelagem PIB

Após realizado a interpolação para transformar os dados de trimestrais para mensais, foi testado três métodos de previsão para a série PIB. A Tabela 13 apresenta os coeficientes de MAPE e MAE de cada modelo testado para a previsão da variável PIB.

Tabela 13: Medidas de acurácia da previsão da variável PIB

PIB	MAPE	MAE
ETS (A,AD,N)	12%	0,23
ARIMA (0,0,6)	3%	0,05
SARIMA (2,0,4)(0,0,2)	2%	0,04

Fonte: Autoria própria (2019)

O modelo que obteve menor MAPE e MAE foi o SARIMA(2,0,4)(0,0,2) e por isso, o seu resultado será incrementado no método SARIMAX para previsão de energia.

5.1.3.2 Modelagem SARIMAX

Ao aplicar a variável exógena PIB, o modelo que melhor se ajustou à série foi o SARIMAX (0,0,0)(1,0,1), e os coeficientes do modelo SARIMAX(0,0,0)(1,0,1) é apresentado abaixo:

Tabela 14: Coeficientes da equação do modelo SARIMAX (0,0,0)(1,0,1)

Parâmetro	Coefficiente
PIB	2,02E-04
SAR(12)	0,982
SMA(12)	0,809

Fonte: Autoria própria (2019)

Este modelo foi escolhido pois apresentou o menor número de Akaike (AIC), conforme demonstrado na Tabela 15.

Tabela 15: Comparativo de AIC dos principais modelos SARIMAX com variável PIB

Model	AIC*
(0,0)(1,1)	-4,5107
(0,0)(2,1)	-4,5106
(0,1)(1,1)	-4,5046
(0,1)(2,1)	-4,5044
(1,0)(1,1)	-4,5043
(1,0)(2,1)	-4,5042
(1,1)(1,1)	-4,5027
(4,2)(2,1)	-4,5023
(0,3)(2,1)	-4,5003
(2,2)(1,1)	-4,4995

Fonte: Autoria Própria (2019)

O Gráfico 13 apresenta a série de dados e a previsão obtida pelo modelo SARIMAX(0,0)(0,1).

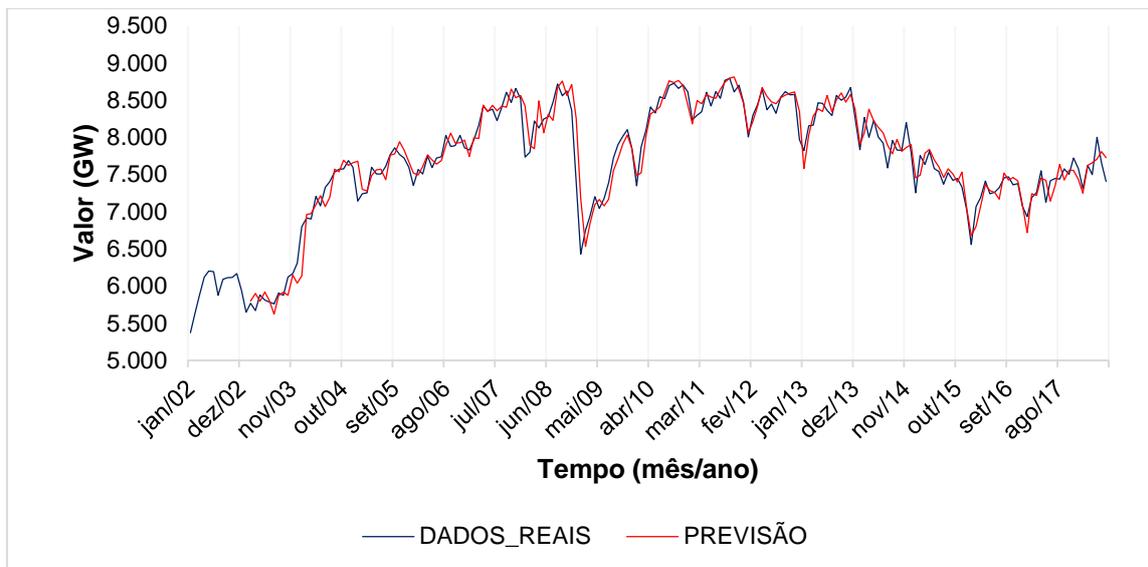


Gráfico 13: Série de dados reais e da previsão obtida através do método SARIMAX PIB – Região Sul

Fonte: Autoria própria (2019)

As medidas de acurácia foram calculadas, e podem ser verificados na Tabela 16.

Tabela 16: Medidas de acurácia da previsão do modelo SARIMAX – PIB para região Sudeste

SUDESTE	MAPE	MAE
SARIMAX_PIB	1,67%	128,9

Fonte: Autoria própria (2019)

5.1.4 SARIMAX com variável IBCR

5.1.4.1 Modelagem IBCR

Os métodos ETS, ARIMA e SARIMA foram aplicados na série sudeste e seus resultados podem ser observados na Tabela 17.

Tabela 17: Medidas de acurácia das modelagens da variável IBCR Sudeste

IBCR SUDESTE	MAPE	MAE
ETS (A,A,M)	0,82%	1,08
ARIMA (4,0,5)	1,42%	1,84
SARIMA(2,0,4)(1,0,1)	0,93%	1,21

Autor: Autoria própria (2019)

O modelo ETS (A,A,M) foi o que apresentou melhor resultado, por isso, ele será incrementado no modelo SARIMAX.

5.1.4.2 Modelagem SARIMAX

Com a variável IBCR o modelo que apresentou melhores resultados para a região Sudeste foi o SARMAX (4,4)(1,2), e sua equação está apresentada abaixo:

Tabela 18: Coeficientes da equação do modelo SARIMAX com variável IBCR

Parâmetro	Coeficiente
IBCR	-2,37E-05
AR(1)	0,464
AR(2)	0,964
AR(3)	0,423
AR(4)	-0,939
SAR(12)	0,996
MA(1)	-0,409

MA(2)	-1,117
MA(3)	-0,409
MA(4)	1,000
SMA(12)	-0,603
SMA(24)	-0,297

Fonte: Autoria Própria (2019)

Este modelo apresentou o menor número de Akaike (AIC), conforme demonstrado na Tabela 19.

Tabela 19: Comparativo de AIC dos principais modelos SARIMAX com variável IBCR

Modelo	AIC*
(4,4)(1,2)	-4,5256
(4,4)(2,2)	-4,5198
(0,0)(1,2)	-4,5131
(0,0)(2,1)	-4,5105
(0,0)(1,1)	-4,5104
(3,3)(2,2)	-4,5098
(3,2)(1,2)	-4,5096
(0,0)(2,2)	-4,5087
(3,2)(2,2)	-4,5074
(2,3)(2,2)	-4,5071

Fonte: Autoria Própria (2019)

O gráfico comparativo entre a série de dados e a previsão pode ser verificado no Gráfico 14.

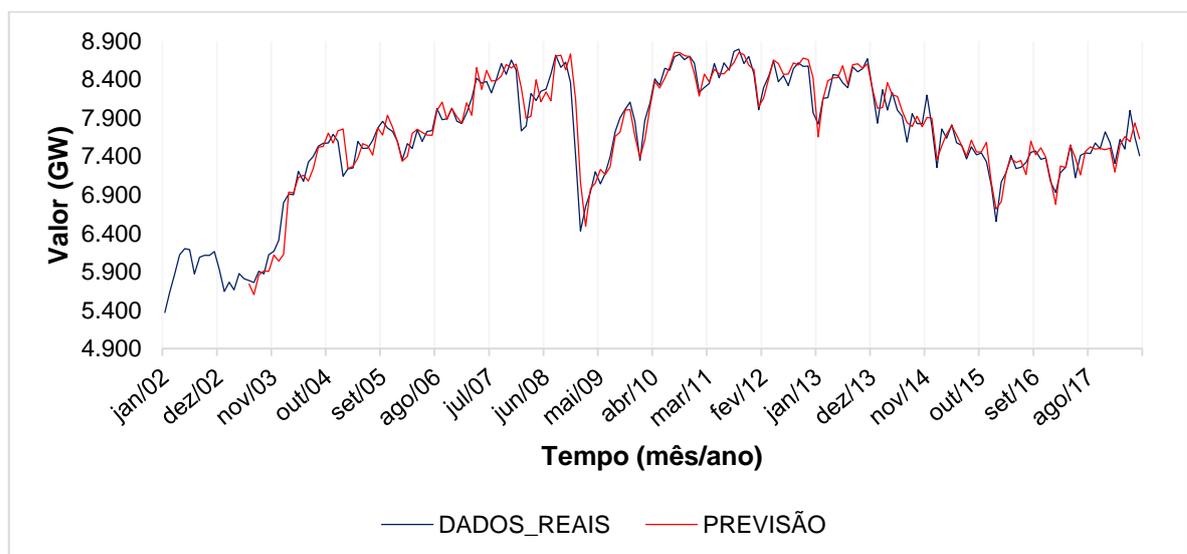


Gráfico 14: Série de dados reais e da previsão obtida através do método SARIMAX IBCR – Região Sudeste

Fonte: Autoria Própria (2019)

As medidas de acurácia foram calculadas levando em consideração os dados dentro da amostra, e podem ser verificados na tabela abaixo.

Tabela 20: Medidas de acurácia – SARIMAX(IBC)R Sudeste

+	MAPE	MAE
SARIMAX_IBCR	1,54%	119,7

Fonte: Autoria própria (2019)

5.1.5 SARIMAX com as variáveis PIB e IBCR

Ao incrementar no método SARIMAX duas variáveis exógenas, IBCR e PIB, o modelo que obteve melhores resultados foi do tipo SARIMAX(0,0,0)(2,0,1)[12], em que sua equação pode ser observada abaixo:

Tabela 21: Coeficientes da equação do modelo SARIMAX com variáveis PIB e IBCR

Parâmetro	Coefficiente
PIB	0,00027
IBC	-0,00003
AR(12)	1,15073
AR(24)	0,15149
MA(12)	0,96317

Fonte: Autoria Própria (2019)

O resultado dos dez principais modelos pode ser verificado na Figura 35.

Tabela 22: Comparativo de AIC dos principais modelos SARIMAX com variáveis PIB e IBCR

Modelo	AIC*
(0,0)(2,1)	-4,5018
(0,0)(1,1)	-4,5012
(0,1)(2,1)	-4,4954
(1,0)(2,1)	-4,4953
(0,1)(1,1)	-4,4950
(1,0)(1,1)	-4,4948
(1,1)(1,1)	-4,4933
(2,2)(1,1)	-4,4902
(3,0)(2,1)	-4,4890
(4,0)(2,1)	-4,4886

Fonte: Autoria Própria (2019)

O Gráfico 15 demonstra o comportamento da série de dados reais e da previsão.

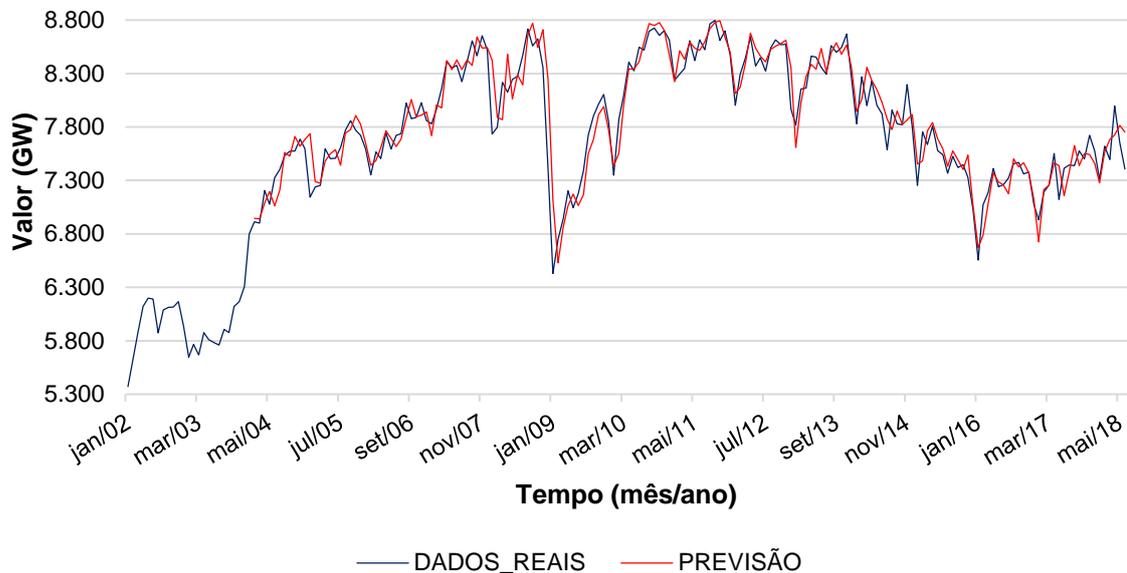


Gráfico 15: Série de dados reais e da previsão obtida através do método SARIMAX PIB e IBCR – Região Sudeste
Fonte: Autoria própria (2019)

Os valores de MAPE e MAE estão descritos na Tabela 23.

Tabela 23: Medidas de acurácia – SARIMAX – PIB e IBCR Sudeste

SUDESTE	MAPE	MAE
SARIMAX_PIB_IBCR	1,64%	126,7

Fonte: Autoria própria (2019)

5.2 REGIÃO SUL

5.2.1 ETS (Error, Trend, Season)

Para a região Sul o modelo que obteve melhores resultados foi o ETS (A,N,M), com erros aditivos, sem tendência e sazonalidade multiplicativa. A equação do

modelo é dada por:

$$\mu_t = l_{t-1}s_{t-m} \quad (21)$$

$$l_t = l_{t-1} + \alpha \varepsilon_t / s_{t-m} \quad (22)$$

$$s_t = s_{t-m} + \gamma \varepsilon_t / l_{t-1} \quad (23)$$

Em que:

l_t = Estimativa de nível, $t = 1, 2, 3 \dots m$

s_t = Estimativa de sazonalidade, $t = 1, 2, 3 \dots m$

α = Parâmetro de estimação para nível

γ = Parâmetro de estimação para sazonalidade

ε_t = Ruído branco

A escolha do melhor modelo foi feita através dos critérios de AIC, cujo comparativo está apresentado na Figura 38 abaixo:

Tabela 24: Comparativo de AIC dos principais modelo ETS – Região Sul

Model	AIC*
A,N,M	2.668,66
A,MD,M	2.669,59
A,A,M	2.669,63
A,M,M	2.670,65
M,AD,M	2.671,61
A,AD,M	2.672,65
M,N,M	2.674,71
M,M,M	2.674,77
A,N,A	2.687,12
A,A,A	2.688,98

Fonte: Autoria Própria (2019)

O gráfico comparativo entre a série de dados e a previsão pode ser observado no Gráfico 16.



Gráfico 16: Série de dados reais e da previsão obtida através do método ETS – Região Sul
Fonte: Autoria própria (2019)

As medidas de acurácia do modelo escolhido foram calculadas e estão apresentadas na Tabela 10.

Tabela 25: Medidas de acurácia da previsão da região Sul via modelo ETS

SUL	MAPE	MAE
ETS(A,N,M)	1,81%	42,1

Fonte: Autoria própria (2019)

5.2.2 SARIMA

O modelo que mais se adequou a série da região Sul, foi o SARIMA(0,0,1)(1,0,1)[12], e os coeficientes da equação são apresentados abaixo:

Tabela 26: Coeficientes da equação do modelo SARIMA – Região Sul

Parâmetro	Coefficiente
SAR(12)	0,97
MA(1)	0,24
SMA(12)	0,59

Fonte: Autoria própria (2019)

Este modelo apresentou o menor número de Akaike (AIC), conforme demonstrado na Figura 41.

Tabela 27: Comparativo de AIC dos principais modelos SARIMA – Região Sul

Modelo	AIC*
(0,1)(1,1)	11,1615
(2,4)(1,2)	11,1661
(4,2)(2,1)	11,1671
(4,2)(1,2)	11,1673
(1,0)(1,1)	11,1675
(2,0)(1,1)	11,1697
(0,1)(1,2)	11,1706
(0,1)(2,1)	11,1706
(2,3)(1,1)	11,1707
(0,2)(1,1)	11,1710

Fonte: Autoria própria (2019)

O gráfico da série é representado pela Figura 42, onde a linha azul representa os dados da série e a linha vermelha a previsão.

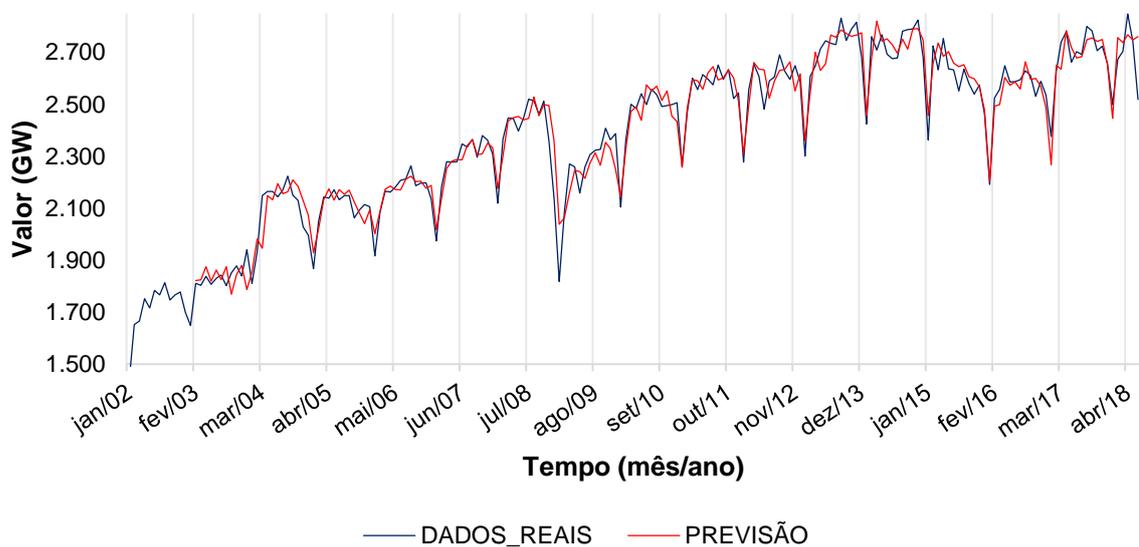


Gráfico 17: Série de dados reais e da previsão obtida através do método SARIMA – Região Sul
Fonte: Autoria própria (2019)

As medidas de acurácia foram calculadas levando em consideração os dados dentro da amostra, e podem ser verificados na tabela abaixo.

Tabela 28: Medidas de acurácia da previsão da região Sul via modelo SARIMA

SUL	MAPE	MAE
SARIMA	1,96%	46,1

Fonte: Autoria própria (2019)

5.2.3 SARIMAX com variável PIB

O modelo que apresentou melhores resultados foi o SARMAX (2,1)(1,2), e os coeficientes do modelo está apresentado na Tabela 29.

Tabela 29: Coeficientes da equação do modelo SARIMAX com variável PIB– Região Sul

Parâmetro	Coeficiente
PIB	1,597
AR(1)	0,730
AR(2)	0,138
SAR(12)	0,973
MA(1)	-1,000
SMA(12)	-0,569
SMA(24)	-0,060

Fonte: Autoria Própria (2019)

Este modelo apresentou o menor número de Akaike (AIC) conforme demonstrado na Tabela 30.

Tabela 30: Comparativo de AIC dos principais modelos SARIMAX com variável PIB – Região Sul

Modelo	AIC*
(2,1)(1,2)	11,1611
(2,4)(1,1)	11,1624
(2,2)(1,1)	11,1632
(2,4)(1,2)	11,1667
(1,4)(1,1)	11,1670
(3,1)(1,2)	11,1707
(2,2)(1,2)	11,1710
(3,2)(1,1)	11,1711
(0,1)(1,1)	11,1716
(1,4)(1,2)	11,1743

Fonte: Autoria própria (2019)

O gráfico da série é representado pelo Gráfico 18, onde a linha vermelha representa os dados da série e a linha azul a previsão.

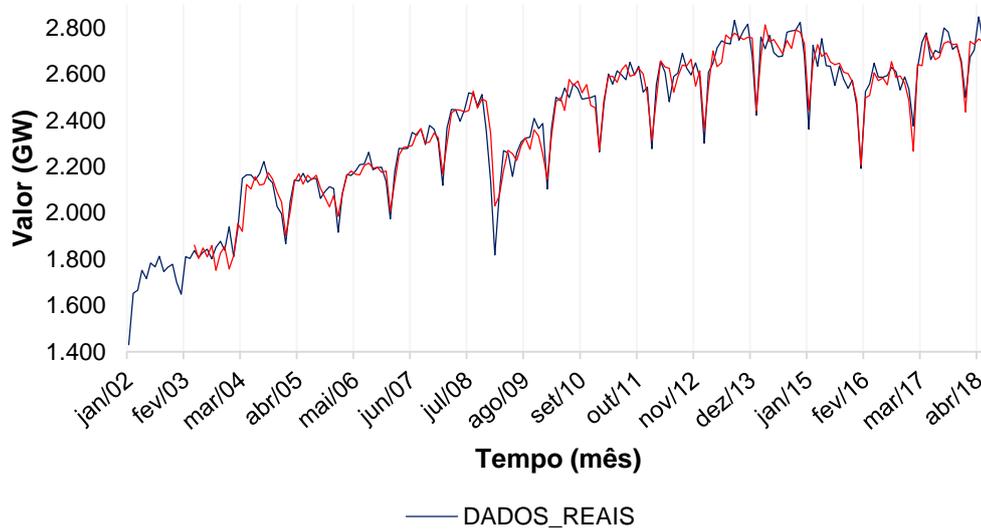


Gráfico 18: Série de dados reais e da previsão obtida através do método SARIMAX (PIB) – Região Sul
Fonte: Autoria própria (2019)

As medidas de acurácia podem ser verificadas abaixo:

Tabela 31: Medidas de acurácia da previsão da região Sul via modelo SARIMAX (PIB)

SUL	MAPE	MAE
SARIMAX PIB	1,89%	44,7

Fonte: Autoria própria (2019)

5.2.4 SARIMAX com a variável IBCR

5.2.4.1 Modelagem IBCR sul

Os métodos ETS, ARIMA e SARIMA foram aplicados na série IBCR sudeste e seus resultados podem ser observados na Tabela 32.

Tabela 32: Medidas de acurácia das modelagens da variável IBCR (SUL)

IBCR SUL	MAPE	MAE
ETS (A,AD,M)	1,80%	2,28
ARIMA (6,6)(0,0)	3,54%	4,58
SARIMA (4,3)(1,1)	1,96%	2,46

Autor: Autoria própria (2019)

O modelo ETS (A,A,M) foi o que apresentou melhor resultado, por isso, ele será incrementado no modelo SARIMAX.

5.2.4.2 Modelagem SARIMAX

Para região Sul o modelo que obteve melhores resultados foi do tipo SARMAX(2,4)(1,2). Os coeficientes da equação correspondente ao modelo estão apresentados abaixo:

Tabela 33: Coeficientes da equação do modelo SARIMAX com variável IBCR– Região Sul

Parâmetro	Coeficiente
IBCR	0,0019
AR(1)	1,9585
AR(2)	-0,9862
SAR(12)	0,9686
MA(1)	-2,2760
MA(2)	1,5088
MA(3)	-0,1486
MA(4)	-0,0731
SMA(12)	-0,5386
SMA(24)	-0,0638

Fonte: Autoria própria (2019)

A Tabela 33 apresenta um comparativo dos critérios de AIC dos dez melhores modelos testados pelo software.

Tabela 34: Comparativo de AIC dos principais modelos SARIMAX (IBCR) – Região Sul

Modelo	AIC*
--------	------

(2,4)(1,2)	11,1578
(4,2)(2,1)	11,1594
(0,1)(1,1)	11,1698
(1,0)(1,1)	11,1759
(2,0)(1,1)	11,1780
(0,1)(1,2)	11,1790
(0,1)(2,1)	11,1790
(0,2)(1,1)	11,1794
(1,1)(1,1)	11,1795
(4,2)(1,1)	11,1795

Fonte: Autoria Própria (2019)

O gráfico da série pode ser visualizado no Gráfico 19.

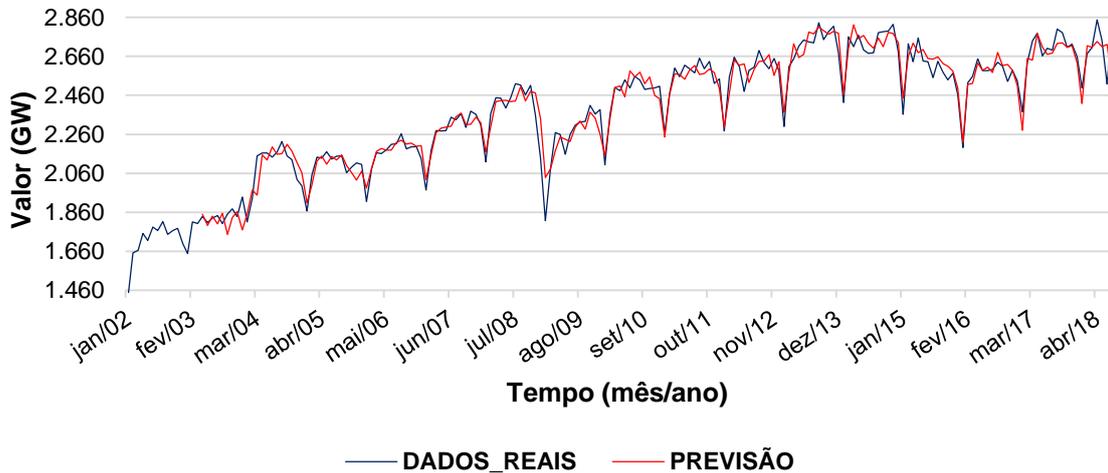


Gráfico 19: Série de dados reais e da previsão obtida através do método SARIMAX (IBCR) – Região Sul

Fonte: Autoria própria (2019)

As medidas de acurácia foram calculadas com o software Excel e podem ser verificados na tabela abaixo.

Tabela 35: Medidas de acurácia – SARIMAX(IBCR) Sul

SUL	MAPE	MAE
SARIMAX IBCR	1,90%	44,9

Fonte: Autoria própria (2019)

5.2.5 SARIMAX com as variáveis PIB e IBCR

O modelo encontrado para a região sul foi do tipo SARMAX(3,2)(1,1) e os coeficientes da equação podem ser verificados abaixo:

Tabela 36: Coeficientes da equação do modelo SARIMAX com variáveis PIB e IBCR– Região Sul

Parâmetro	Coeficiente
PIB	1,2642
IBCR	0,0117
AR(1)	-0,2359
AR(2)	0,8411
AR(3)	0,1366
SAR(12)	0,9651
MA(1)	-0,0400
MA(2)	-0,9600
SMA(12)	-0,5822

Fonte: Autoria própria (2019)

O comparativo do número de AIC está representado na Tabela

Tabela 37: Comparativo de AIC dos principais modelos SARIMAX (PIB e IBCR) – Região Sul

Modelo	AIC*
(3,2)(1,1)	11,1798
(0,1)(1,1)	11,1808
(1,0)(1,1)	11,1866
(4,2)(1,1)	11,1887
(2,0)(1,1)	11,1891
(0,1)(2,1)	11,1900
(0,2)(1,1)	11,1904
(1,1)(1,1)	11,1905
(1,0)(2,1)	11,1956
(4,2)(2,1)	11,1970

Fonte: Autoria própria (2019)

O gráfico deste modelo e da série original pode ser verificado no Gráfico X.

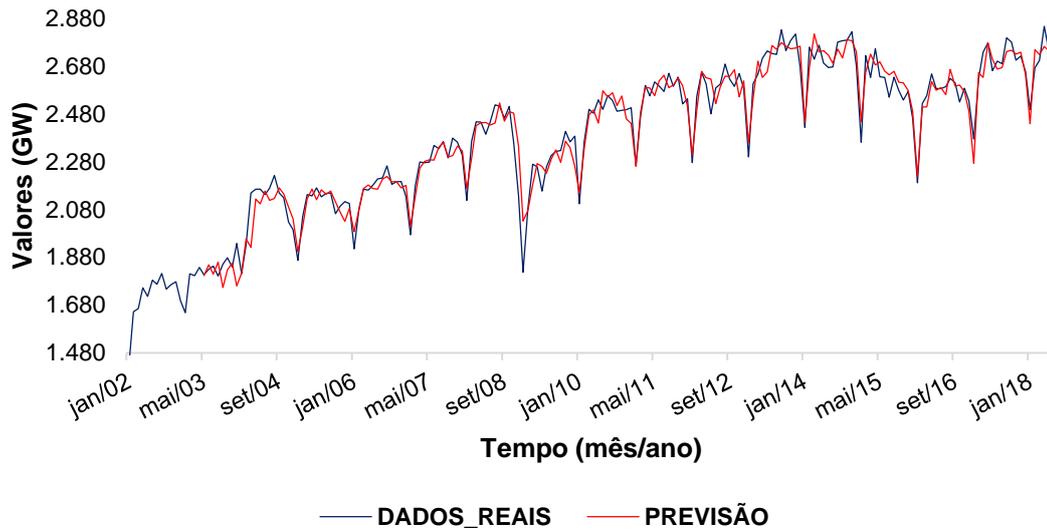


Gráfico 20: Série de dados reais e da previsão obtida através do método SARIMAX (IBCR) – Região Sul

Fonte: Autoria própria (2019)

As medidas de acurácia estão descritas na Tabela 15.

Tabela 38: Medidas de acurácia – SARIMAX(PIB e IBCR) Sul

SUL	MAPE	MAE
SARIMAX	1,89%	44,75

Fonte: Autoria própria (2019)

5.3 COMPARATIVO E APRESENTAÇÃO DA PREVISÃO

5.3.1 Região Sudeste

Todos os métodos apresentaram resultados satisfatório, pois apresentaram um erro relativamente pequeno conforme demonstra a Tabela 39.

Tabela 39: Comparativo entre medidas de acurácia das previsões da região Sudeste

Região Sudeste	MAPE	MAE
ETS	1,49%	115,50
SARIMA	1,61%	122,83
SARIMAX PIB	1,67%	128,90

SARIMAX IBCR	1,54%	119,70
SARIMAX PIB E IBCR	1,64%	126,70

Fonte: Autoria própria (2019)

O método que obteve melhor resultado para o cálculo de erro dentro da amostra foi o ETS (A,M,M) com uma taxa média de 1,49% e um MAE de 115,50 GW.

A Tabela 40 apresenta os dados da previsão e seus respectivos MAP e MAE para cada ponto do período previsto.

Tabela 40: Medidas de acurácia mensal, dados reais e previsão– Região Sudeste

mês	DADOS_REAIS	PREVISÃO	MAPE	MAE
jul/18	7.580	7.370	2,77%	209,77
ago/18	7.802	7.567	3,01%	235,05
set/18	7.939	7.578	4,55%	361,46
out/18	7.733	7.560	2,24%	173,41
nov/18	7.962	7.623	4,26%	338,90
dez/18	7.664	7.356	4,02%	308,15
jan/19	7.300	7.007	4,02%	293,30
fev/19	7.371	7.265	1,43%	105,55
mar/19	7.428	7.320	1,45%	107,70
abr/19	7.404	7.562	2,13%	157,57
mai/19	7.568	7.422	1,93%	146,42
jun/19	7.382	7.472	1,21%	89,56

Fonte: Autoria própria (2019)

A previsão apresentou MAPE médio de 2,75% e MAE de 210,57. A Figura 52 mostra o gráfico da série original e da prevista.

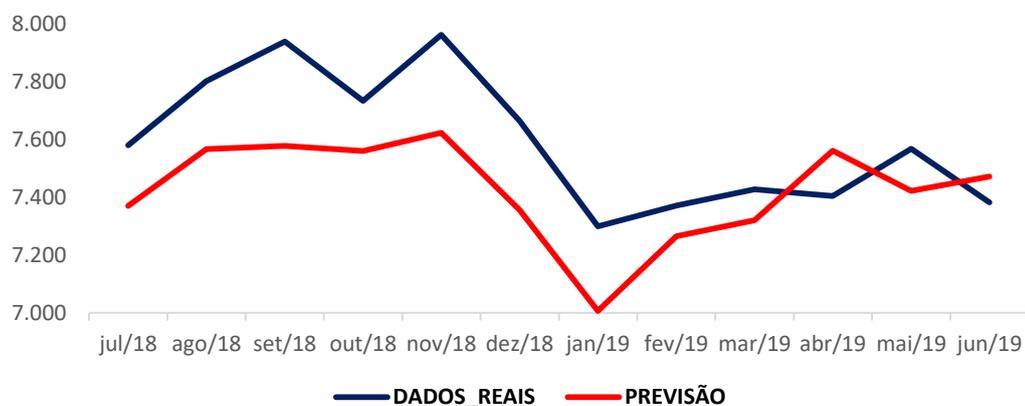


Gráfico 21: Comparativos entre os dados reais e a previsão pelo modelo ETS
Fonte: Autoria própria (2019)

5.3.2 Região Sul

Para a região sul, os cinco modelos também apresentaram resultados satisfatórios. O detalhamento dos erros pode ser verificado na Tabela 18.

Região Sul	MAPE	MAE
ETS	1,81%	42,07
SARIMA	1,96%	46,14
SARIMAX PIB	1,89%	44,72
SARIMAX IBCR	1,90%	44,9
SARIMAX PIB E IBCR	1,89%	44,75

Gráfico 22: Comparativo de erros da região sul
Autor: Autoria própria

O modelo ETS (A,N,M) foi o modelo que apresentou o melhor resultado, pois obteve os menores erros dentro da amostra.

A previsão para o período de julho de 2018 a junho de 2019 obteve os seguintes resultados:

Tabela 41: Medidas de acurácia mensal– Região Sul

MÊS	DADOS_REAIS	PREVISÃO	MAPE	MAE
jul/18	2.776	2.598	6,43%	178,5
ago/18	2.861	2.645	7,54%	215,7
set/18	2.786	2.594	6,91%	192,5
out/18	2.747	2.597	5,47%	150,2
nov/18	2.795	2.580	7,68%	214,6
dez/18	2.670	2.513	5,87%	156,7
jan/19	2.570	2.276	11,45%	294,3
fev/19	2.709	2.536	6,39%	173,0
mar/19	2.777	2.605	6,21%	172,3
abr/19	2.725	2.636	3,28%	89,4
mai/19	2.818	2.590	8,10%	228,4
jun/19	2.780	2.589	6,87%	190,9

Fonte: Autoria própria (2019)

No qual o MAPE médio foi de 6,85% e o MAE foi de 188,03GW. A Figura 53 representa a demonstração gráfica da previsão e dos dados reais.

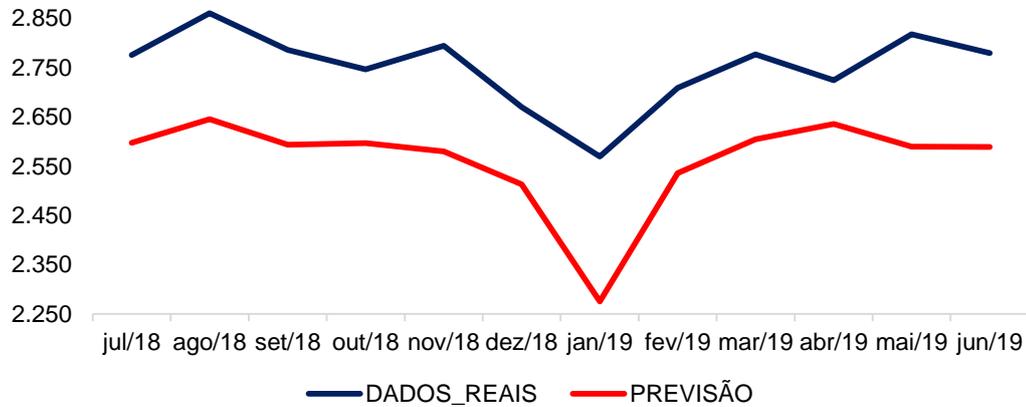


Gráfico 23: Comparativos de resultado de modelos - sul
Fonte: Autoria própria (2019)

Graficamente pode-se perceber que a série de previsão acompanhou os crescimentos e decrescimentos dos valores reais, com exceção dos meses de maio e junho de 2019, que apresentaram crescimento contrário ao do realizado.

6 CONCLUSÃO

As empresas de distribuição necessitam de maior acurácia em suas previsões de demanda, a fim de reduzirem seus riscos. As previsões de médio prazo são utilizadas para o planejamento de produção e possíveis estratégias produtivas, como compra de maquinário ou combustível, e utilização de energia proveniente de usinas termoelétricas.

Este trabalho propôs realizar previsões de consumo de energia elétrica do setor industrial nas regiões sul e sudeste para o período de julho de 2018 a junho de 2019. A metodologia foi aplicada motivada pelo fato de a energia não ser um bem estocável e por isso necessitar de uma maior acuracidade nos resultados das projeções. Foram utilizadas 198 observações mensais e aplicado cinco modelos para cada região.

As variáveis IBCR e PIB foram incrementadas nos modelos da classe ARIMA. A variável PIB apresentou baixo poder explicativo para região sul, tendo um coeficiente de $-0,17$ e uma correlação moderada com a região sudeste, com coeficiente de $0,37$. Em contrapartida, a variável IBCR apresentou correlação alta para ambas as regiões, possuindo um coeficiente de determinação de $0,67$ para região sudeste e $0,76$ para região sul.

De forma geral, todos os modelos apresentaram resultados satisfatórios, visto que a taxa de erro obtido foi baixa. Ao comparar as medidas de acurácia de cada região, o modelo ETS apresentou em ambas as séries os melhores desempenhos, e por isso foi escolhido como melhor modelo, e a partir dele foi realizado a previsão para o período proposto. Apesar de a variável PIB apresentar correlação baixa, o resultado do modelo também foi considerado satisfatório.

7 SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros, sugere-se a implementação de outros modelos de previsão como por exemplo redes neurais e avaliar a incrementar novas variáveis exógenas, como por exemplo: número de unidades consumidoras, temperatura média e valor da tarifa.

REFERÊNCIAS

ANEEL. **Atlas de energia elétrica do Brasil / Agência Nacional de Energia Elétrica**, Aneel, 3. ed. – Brasília, 2008.

ANEEL. **Matriz energética brasileira**. 2017. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm>>. Acesso em: 07 nov. 2018.

ALEIXO, Márcio Vinicius. **Projeção da demanda de energia elétrica da cidade de Londrina**. 2015. 117 f. TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Estadual de Londrina, Londrina, 2015.

BCB, Banco Central do Brasil. **Índice de Atividade Econômica Regional (IBCR): revisão metodológica**. 2017. Disponível em: <<https://www.bcb.gov.br/pec/boletimregional/port/2017/04/br201704b3p.pdf>>. Acesso em: 08 nov. 2018.

BOX, G.E.; JENKINS, G.M.; REINSEL, G.C.; LJUNG, G.M. **Time series analysis: forecasting and control**. New York: John Wiley & Sons, 2015.

BRASIL. **Entenda como é medido o Produto Interno Bruto (PIB)**. 2016. Disponível em: <<http://www.brasil.gov.br/economia-e-emprego/2016/06/entenda-como-e-medido-o-produto-interno-bruto-pib>>. Acesso em: 06 set. 2018.

CAMPOS, R.J. **Previsão de Séries Temporais com Aplicação a Séries de Consumo de Energia Elétrica**. 2008. 85 f. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, MG. 2008.

CASAGRANDE, Dieison Lenon et al. Métodos de previsão para a taxa de desemprego mensal: uma análise de séries temporais. **Revista de Economia da Ueg**, Anápolis, v. 12, n. 1, p.58-86, Não é um mês valido! 2016. Disponível em: <<http://www.revista.ueg.br/index.php/economia/article/view/4685/3208>>. Acesso em: 01 nov. 2018.

COELHO JUNIOR, Luiz Moreira et al. Previsão do consumo de eletricidade no nordeste brasileiro. **Engvista**, [s.i.], v. 20, n. 3, p.408-423, jul. 2018.

COSTANZA, R.; HART, M.; TALBERTH, J.; POSNER, S. **Beyond GDP: The need**

for new measures of progress. The Pardee papers. Boston University. v.4, 2009

DANCEY, Christine; REIDY, John. **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows.** 3 ed. Porto Alegre, Artmed, 2006.

DOYLE, P.; FENWICK, I.A. **Sales Forecasting — Using a Combination of Approaches.** *Long-Range Planning*, v. 9, n. 3, p. 60-69, 1976

EPE, Empresa de Pesquisa Energética. **Energia Termelétrica:** Gás natural, biomassa, carvão nuclear. 2016. Disponível em: <<http://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-173/Energia%20Termel%C3%A9trica%20-%20Online%2013maio2016.pdf>>. Acesso em: 11 nov. 11.

EPE, Empresa de Pesquisa Energética. **Consumo de Energia Elétrica.** ---. Disponível em: <<http://www.epe.gov.br/pt/areas-de-atuacao/energia-eletrica/consumo-de-energia-el%C3%A9trica>>. Acesso em: 17 set. 2018.

EMPRESA DE PESQUISA ENERGÉTICA EPE. . **Projeção da demanda de energia elétrica.** Rio de Janeiro: 2017. Disponível em: <[http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-245/topico-261/DEA%20001_2017%20-%20Proje%C3%A7%C3%B5es%20da%20Demanda%20de%20Energia%20EI%C3%A9trica%202017-2026_VF\[1\].pdf](http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-245/topico-261/DEA%20001_2017%20-%20Proje%C3%A7%C3%B5es%20da%20Demanda%20de%20Energia%20EI%C3%A9trica%202017-2026_VF[1].pdf)>. Acesso em: 13 nov. 2018.

ESPINOSA, Mariano Martinez; PRADO, Silvia Maria; GHELLERE, Maikelli. Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natura**, Santa Maria, v. 32, n. 2, p.7-21, 21 jul. 2010.

FAVA, V. L. **Manual de econometria.** In: VASCONCELOS, M. A. S.; ALVES, D. São Paulo: Editora Atlas, 2000.

FERNANDES, Flavio Cesar Faria; GODINHO FILHO, Moacir. **Planejamento e controle da Produção.** São Paulo: Atlas, 2010.

FIGUEIREDO FILHO, Dalson Britto; SILVA JÚNIOR, José Alexandre da. **Desvendando os mistérios do coeficiente de correlação de Pearson (r).** 2009. Disponível em: <<https://periodicos.ufpe.br/revistas/politica hoje/article/view/3852/3156>>. Acesso em: 08 out. 2018.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. 5. ed. São Paulo: Atlas, 2010. 184 p.

GOLDEMBERG, J.; LUCON, O. **Energia, meio ambiente e desenvolvimento**. 3. ed. São Paulo: Edusp, 2008.

GROSS, Márcio Margelo et al. Análise da Demanda de Energia Elétrica no Setor Industrial no Brasil. **Economia Política do Desenvolvimento**, Maceió, v. 8, n. 19, p.69-93, jan. 2018.

IBGE. . **Pesquisa Anual do Serviços**. 2017. Disponível em: <<https://ww2.ibge.gov.br/home/estatistica/economia/comercioeservico/pas/analisepas99.shtm>>. Acesso em: 12 nov. 2018.

IRFFI, Guilherme et al. Previsão da demanda por energia elétrica para classes de consumo na região Nordeste, usando OLS dinâmico e mudança de regime. **Economia Aplicada**, Ribeirão Preto, v. 13, n. 1, p.69-89, jan. 2009. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-80502009000100004&lng=pt&nrm=iso&tling=pt>. Acesso em: 09 nov. 2018.

HAHN, H., NIEBERG, S.M., PICKL, S., 2009. Electric load forecasting methods: Tools for decision making. **European Journal of Operational Research**, v. 199, n. 3 (Dez), pp. 902–907.

Hyndman, RJ, Koehler, AB, Ord, JK e Snyder, RD (2008). **Previsão com suavização exponencial: a abordagem do espaço de estados** . Berlim: Springer-Verlag.

KLAFKE, Renata Vidart. **Comparação entre os níveis tecnológicos do Brasil e da China em relação ao PIB e o IDH**. 2016. 104 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2016.

KAUARK, F. da S.; MANHÃES, F. C.; MEDEIROS, C. H. **Metologia da Pesquisa: Um guia prático**. Itabuna: Via Litterarum, 2010. 88 p.

LUSTOSA, Leonardo et al (Org.). **Planejamento e Controle da Produção**. 1. ed. Rio de Janeiro: Elsevier Editora Ltda, 2008. 357 p

MARCONI, M. A. de; LAKATOS, E. M. **Fundamentos de Metodologia Científica**. 6. ed. São Paulo: Atlas, 2009. 315 p.

MARTINS, Gilberto de Andrade. **Estatística geral e aplicada**. 2. ed. São Paulo: Editora Atlas, 2002. 417 p.

MARTINS, Petrônio G.; LAUGEN, Fernando P.. **Administração da produção**. 3. ed. São Paulo: Saraiva, 2015.

MARTINS, Vera Lúcia Milani. **Comparação de previsões individuais e suas combinações**: um estudo com séries industriais. 2011. 100 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

MATOS, Orlando Carneiro de. **Econometria básica**: aplicação e teoria. 3. ed. São Paulo: Atlas, 2000.

MENDIONDO, Roberta; OLIVEIRA, Paulo Sergio Sousa. Métodos de previsão de consumo de energia elétrica regressão e redes neurais artificiais. In: CONGRESSO NACIONAL EM EXCELÊNCIA EM GESTÃO, 10., 2014, [s.i]. **Congresso**. Rio de Janeiro: [s.i], 2014.

MOHAMMED, Nooriya A.. Modelling of unsuppressed electrical demand forecasting in Iraq for long term. **Energy**, [s.l.], v. 162, p.354-363, nov. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2018.08.030>.

MONKS, Joseph G. **Administração da produção**. São Paulo: McGraw-Hill, 1987.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Livraria Pioneira Editora, 1993.

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

MOURA, F.A.; MONTINI, A.A.; CASTRO, J.B.B. (2011) **Modelagem do Consumo de Energia Elétrica Residencial no Brasil Através de Modelos ARMAX**. In: SEMINÁRIO DE ADMINISTRAÇÃO, 14., 2011. Anais...

MOURA, Fernando Alves de. **Previsão do consumo de energia elétrica por setores através do modelo SARMAX**. 2011. 138 f. Dissertação (Mestrado) - Curso de Administração, Universidade de São Paulo, São Paulo, 2011.

NASIRU, S.; LUGUTERAH, A.; ANZAGRA, L. (2013). **The Efficacy of ARIMAX and SARIMA Models in Predicting Monthly Currency in Circulation in Ghana. Mathematical Theory and Modeling**, 3(5), 73–81.

NEVES, Gustavo Costa Moura; VIVAS, Hugo Catalão Simas. **Previsão do consumo industrial de energia elétrica por região do Brasil**. 2018. 237 f. TCC (Graduação) - Curso de Engenharia de Produção, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018.

ORD, K. Commentaries on the M3-competition. An. Introduction, some comments and scorecard. **International Journal of Forecasting**. v. 17, p. 537-584, 2001.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2. ed. Novo Hamburgo: Feevale, 2013.

PEREIRA, Cesar Machado; ALMEIDA, Nival Nunes de; VELLOSO, Maria L.f.. Fuzzy Modeling to Forecast an Electric Load Time Series. **Procedia Computer Science**, [s.l.], v. 55, p.395-404, 2015. Elsevier BV.
<http://dx.doi.org/10.1016/j.procs.2015.07.089>.

ROCHA JUNIOR, Eloy de Paula. **Metodologia Para Previsão De Demanda Baseada Em Cenários Utilizando Densidade De Carga E Temperatura**. 2011. 117 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal do Paraná, Curitiba, 2011. Disponível em:
<<https://acervodigital.ufpr.br/handle/1884/29787>>. Acesso em: 8 de out. 2018.
2005.

SHIMAKURA, S.E. **Coeficiente de determinação**. 2006. Disponível em:
<http://leg.ufpr.br/~silvia/CE003/node74.html>. Acesso em: 03 de dezembro de 2019.

SOUZA, Reinaldo Castro e CAMARGO, M.E. **Análise e previsão de séries temporais. Os modelos ARIMA**", 2 ed., 2004.

SHUKLA, M.; JHARKHARIA, S. (2013). Applicability of ARIMA models in wholesale vegetable market: An investigation. **International Journal of Information Systems**

and Supply Chain Management, 1125–1130

TOLMASQUIM, M. T.; GUERREIRO, A.; GORINI, R. **Matriz energética brasileira: uma prospectiva**. Novos Estudos, 2007.

TUBINO, Dalvio Ferrari. **Planejamento e controle da Produção**. 2. ed. São Paulo: Atlas, 2009.

TURRIONI, J. B.; MELLO, C. H. P. **Metodologia de pesquisa em engenharia de produção**: estratégias, métodos e técnicas para condução de pesquisas quantitativas e qualitativas. 2012. Programa de Pós-graduação em Engenharia de Produção, Universidade Federal de Itajubá, Itajubá, 2012.

WANG, Qiang; LI, Shuyu; LI, Rongrong. Forecasting energy demand in China and India: Using single-linear, hybrid-linear, and non-linear time series forecast techniques. **Energy**, [s.l.], v. 161, p.821-831, out. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2018.07.168>.

WERNER, Liane; RIBEIRO, José Luis Duarte. **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais**. Gestão & Produção (UFSCAR. Impresso), São Carlos - SP, v. 10, n.1, p. 47-68, 2003.