

PREVISÃO DE CONSUMO DE ENERGIA ELÉTRICA UTILIZANDO A METODOLOGIA BOX-JENKINS

Elyrouse Cavalcante de Oliveira Bellini

elyrouse@gmail.com

Márcio Nunes da Silva

marcio_nunessilva@hotmail.com

Wilton Bernardino

wilton.silva@ufpe.br

VALDEMIR SILVA

valdemir.academico@gmail.com



O objetivo deste estudo foi identificar um modelo de previsão que melhor se ajuste a série temporal de consumo de energia elétrica por meio da metodologia Box-Jenkins. Para tanto, utilizou-se como amostra a quantidade do consumo de energia elétrica no Brasil, durante o período de 2007 a 2016, totalizando 129 observações. Os dados foram coletados do Instituto de Pesquisa Econômica Aplicada (IPEA) e tiveram como fonte a Eletrobrás. Do pacote 'forecast', foram utilizados as funções: auto.arima e a função seas. Para realizar a previsão, utilizou-se a função 'predict' para o ano de 2017 e 2018, e os valores reais para calcular os erros. A função auto.arima apontou um modelo SARIMA(1,0,2)(1,0,1)[12] com melhor ajuste, seguindo pelo mesmo modelo SARIMA (0,0,2)(2,0,0)[12] com variável dummy representando a crise de 2008.

Palavras-chave: Séries Temporais, Consumo de energia elétrica, Modelo Box-Jenkins, Previsão

1. Introdução

A demanda por energia elétrica encontra-se em um nível cada vez maior e assume uma tendência de crescimento ao longo dos anos por conta do desenvolvimento tecnológico e econômico dos países. Este tipo de energia é um dos insumos mais usados no mundo, como fonte de calor, luz e força, a qual é produzida por usinas, turbinas e geradores (SCHMIDT & LIMA, 2004; CARNEIRO, 2014). Ao mesmo tempo em que há a ampliação no consumo de energia elétrica oriundo de questões tecnológicas e econômicas, existe também um incremento na conscientização social e organizacional sobre a importância de otimizar o uso da energia, seja por meio de construções sustentáveis, uso de tecnologias renováveis ou pela adoção de fontes alternativas de energia.

Em relação ao contexto brasileiro, Tidre *et al.* (2013) afirmam que o país enfrenta grandes desafios referentes aos impactos socioambientais proporcionados pelo investimento associado as indústrias energéticas, como os alagamentos provocados pelas represas e as desapropriações de famílias da zona rural oriundas das usinas hidrelétricas, a alta liberação de poluentes na atmosfera por usinas termelétricas e a contaminação pelos rejeitos da produção de energia nuclear, entre outras consequências. Assim, é preciso viabilizar alternativas que auxiliem o processo de tomada de decisão e a gestão de sistemas energéticos, visando um melhor direcionamento das ações e recursos nesse âmbito.

Nesse sentido, o uso de ferramentas e modelos econométricos pode contribuir para uma melhor compreensão da evolução do consumo energético do país, bem como atuar como fundamento de apoio ao processo decisório em gestão energética. Dentre as várias abordagens adotadas na econometria, a metodologia *Box-Jenkins* é uma das mais utilizadas nas previsões de séries temporais, pois constituem em modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras eficientes (WERNER & RIBEIRO, 2003).

A partir disso, o presente estudo visa estabelecer um modelo de previsão que permita um ajuste mais favorável das séries temporais de consumo de energia elétrica no Brasil mediante o uso da metodologia *Box-Jenkins*. Para tanto, foram utilizados os dados dos relatórios dos

períodos de 2007 a 2016 do Instituto de Pesquisa Econômica Aplicada (IPEA) baseados nas estatísticas obtidas pela Eletrobrás, responsável por grande parte dos sistemas de geração e transmissão de energia elétrica do Brasil.

2. Revisão teórica

2.1. Consumo de energia no Brasil

Mediante a atual instabilidade política e econômica brasileira, o segmento de energia elétrica admitiu um decréscimo de 0,9% no consumo de energia, ficando em torno de 460.001 GWh em 2016, configurando a maior queda no setor industrial (2,9%). Entretanto, a geração de energia elétrica admitiu níveis significativos. A Usina Hidrelétrica de Itaipu bateu seu recorde anual de geração chegando a 103.098.366 MWh²/ano, retornando ao posto de usina hidrelétrica com maior produção anual no mundo; além disso, as usinas nucleares de Angra dos Reis (Angra I e Angra II) também registraram valor recorde de geração em 2016, gerando cerca de 15,9 TWh (ELETROBRÁS, 2016).

De acordo com a Empresa de Pesquisa Energética (EPE), em 2017, o consumo de energia elétrica na rede totalizou 39.543 GWh em novembro deste ano, apresentando um acréscimo de 2,4% em relação ao mesmo mês do ano de 2016, obtendo o melhor resultado para o mês desde 2014. Ao tempo que o mercado nacional exibiu redução de 2,5% em novembro e de 5,8% no período de 12 meses, o consumo livre aumentou 14,5% no mês e 19% em 12 meses. Portanto, verifica-se uma retomada no crescimento do consumo de energia, após o período de crise.

Algumas medidas foram efetivadas visando à retomada dos negócios no setor elétrico (ELETROBRÁS, 2016), como a Resolução Normativa Aneel 699/2016, que disciplina a prática de atos entre partes relacionadas, e permite o compartilhamento de infraestrutura e recursos humanos; o Decreto 8.828/2016, que alterou o modelo de comercialização de energia elétrica no Brasil; a Resolução Normativa Aneel 711/2016, que versa sobre o aprimoramento de mecanismos em acordos bilaterais; a Lei 13.360/2016, que relaciona-se à gestão de recursos setoriais e a Lei 13.334/2016, que criou o Programa de Parcerias de Investimentos (PPI), objetivando a ampliação e fortalecimento da interação entre o Estado e a iniciativa

privada na execução de empreendimentos públicos de infraestrutura e de outras medidas de desestatização.

2.2 Previsão de séries temporais

Uma série temporal é definida como um conjunto de observações dos valores que uma variável assume em diferentes momentos do tempo (GUJARATI & PORTER, 2011). A análise de séries temporais se aplica nos casos em que há um padrão persistente ou sistemático no comportamento da variável, que é possível de captar através de uma representação paramétrica (PINDYCK & RUBENFIELD, 1991). Os dados podem ser coletados em intervalos de tempo regulares diferenciados: diariamente, trimestralmente, semestralmente, etc., e a natureza destes irá depender do objetivo de quem irá manipulá-los ou da disponibilidade.

Um modelo de série temporal pode ser multivariado ou univariado. Brooks (2007) define um modelo de série temporal univariado como uma classe de especificações onde se tenta modelar e prever variáveis financeiras usando apenas informações contidas em seus próprios valores passados e, possivelmente, valores atuais e passados de um termo de erro. Em contraste, os modelos de natureza multivariada tentam explicar mudanças em uma variável em função das alterações nos valores atuais ou passados de outras variáveis explicativas (BROOKS, 2007).

Os modelos de séries temporais são úteis para prever, por exemplo, variáveis econômicas, como os preços das ações, as taxas de desemprego, o PIB, a inflação, as taxas de juros, entre outras. Entre os diversos modelos existentes, existem cinco abordagens para a previsão econômica que se baseiam nos dados de séries temporais (GUJARATI & PORTER, 2011): métodos de suavização exponencial, modelos de regressão uniequacionais, modelos de regressão de equação simultânea, processo autorregressivo integrado de média móvel (ARIMA) e modelos de vetores autorregressivos (VAR). Um método de previsão bastante popular é o processo autorregressivo integrado de média móvel (ARIMA) ou metodologia *Box-Jenkins*, o qual foi empregado na seguinte pesquisa.

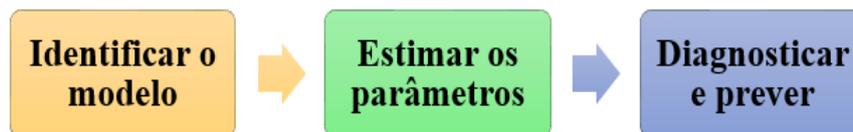
2.2.1. Metodologia *Box-Jenkins*

O uso de séries temporais pressupõe que estas sejam estacionárias, ou seja, que sua média, variância e autocovariâncias (em variadas defasagens) permaneçam constantes, não importando em que ponto sejam mensuradas (BROOKS, 2007; GUJARATI & PORTER, 2011). Entretanto, algumas séries temporais apresentam, naturalmente, um comportamento não estacionário. Nestes casos de não estacionariedade, a série temporal apresentará uma média que varia com o tempo, ou uma variância que varia com o tempo, ou, ainda, ambas (GUJARATI & PORTER, 2011). Entre os benefícios da estacionariedade de uma série temporal, pode-se citar o valor prático proporcionado pelas previsões e generalizações realizadas para períodos futuros. Entretanto, quando uma série temporal é “não estacionária”, o estudo do comportamento de um conjunto de dados será específico a cada momento estudado, ou seja, não será possível generalizar os resultados para outros períodos.

Nesse contexto não-estacionário, a metodologia *Box-Jenkins*, pode ser utilizada para transformar uma série não-estacionária em uma série estacionária na medida em que sucessivas diferenças são aplicadas. Também conhecida, tecnicamente, por Modelo Autoregressivo Integrado de Média Móvel (ARIMA - *Autoregressive Integrated Moving Average*), consiste em permitir que os dados falem por si mesmos, através da análise estocástica, das propriedades da própria série temporal econômica, além disso, viabiliza que valores passados, ou defasados, do próprio Y e dos termos de erro estocástico possam explicar Y_t (POKORNY, 1987; BROOKS, 2007; GUJARATI & PORTER, 2011).

De acordo com Roumani *et al.* (2015), as previsões por meio do modelo ARIMA devem ser baseadas em três etapas principais, conforme figura 1. Além disso, é importante confirmar a estacionariedade da série. A estacionariedade do modelo ARIMA é examinada por meio de dois testes: o teste de Dickey-Fuller e o teste da raiz da unitária de Phillips-Perron.

Figura 1 - Etapas para a construção de um modelo ARIMA



Fonte: Adaptado de Roumani *et al.* (2015)

A primeira etapa de construção do modelo ARIMA, envolve a *identificação do modelo* que especifica a estrutura e a ordem apropriada deste. O modelo ARIMA é estruturado em três

componentes: p que consiste no número de termos autorregressivos (AR); d que corresponde ao número de vezes que a série pode ser diferenciada antes de se tornar estacionária; e q que agrega o número de termos da média móvel (MA) (BROOKS, 2007; GUJARATI & PORTER, 2011; ROUMANI, NWANKPA & ROUMANI, 2015).

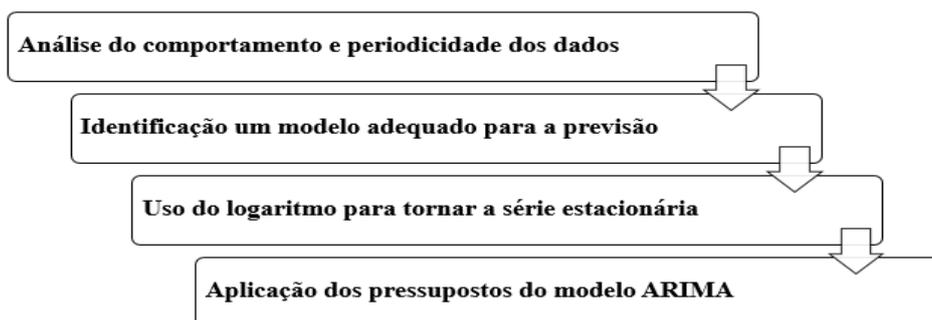
A segunda parte da construção do modelo ARIMA trata da *estimativa dos parâmetros* por máxima verossimilhança ou métodos de mínimos quadrados, a depender do modelo. Enquanto que a terceira etapa do processo envolve o *diagnóstico e a previsão*. O diagnóstico visa garantir que os parâmetros estimados sejam estatisticamente significativos e que os resíduos do modelo sejam aleatórios. Em relação à previsão, Gujarati & Porter (2011) afirmam que o método ARIMA corrobora com uma maior confiabilidade da previsão se comparado com os modelos econométricos tradicionais, sobretudo para as previsões de curto prazo.

3. Metodologia

A pesquisa admite características exploratório-descritiva, pois objetiva uma compreensão significativa do objeto investigado e a apresentação e descrição do objeto de pesquisa. Em relação ao tipo de abordagem, a pesquisa pode ainda ser classificada como quantitativa, pois implica no tratamento estatístico dos dados. Em relação aos procedimentos, a avaliação em questão foi estabelecida mediante pesquisa bibliografia e documental.

Utilizou-se como base de dados os relatórios do Instituto de Pesquisa Econômica Aplicada (IPEA) que foram fundamentados em estatísticas obtidas pela Eletrobrás, relativos aos anos de 2007 a 2016. A variável resposta corresponde a quantidade do consumo de energia elétrica no Brasil em gigawatt-hora/mês. Ao todo foram utilizadas 129 observações e a modelagem da base de dados foi realizada mediante o uso do *software R*, versão 3.4.3. As etapas da metodologia estão dispostas na figura 2.

Figura 2 - Etapas da metodologia.



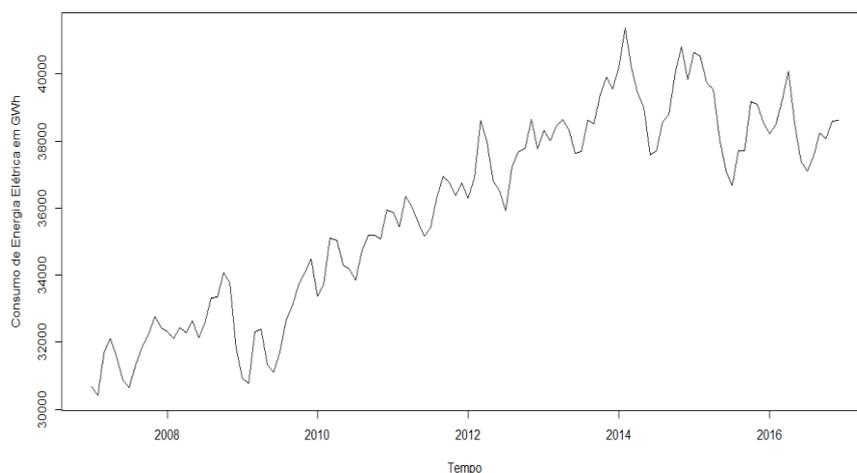
Fonte: Elaboração Própria (2018)

4. Análise e discussão dos resultados

4.1. Série temporal original

A figura 3 apresenta a série de Consumo de Energia Elétrica - CEET do período de janeiro de 2007 a janeiro de 2016. Observa-se a tendência crescente e um componente aparentemente sazonal na decomposição da série, dessa forma, torna-se necessário remover o efeito da tendência na modelagem da série.

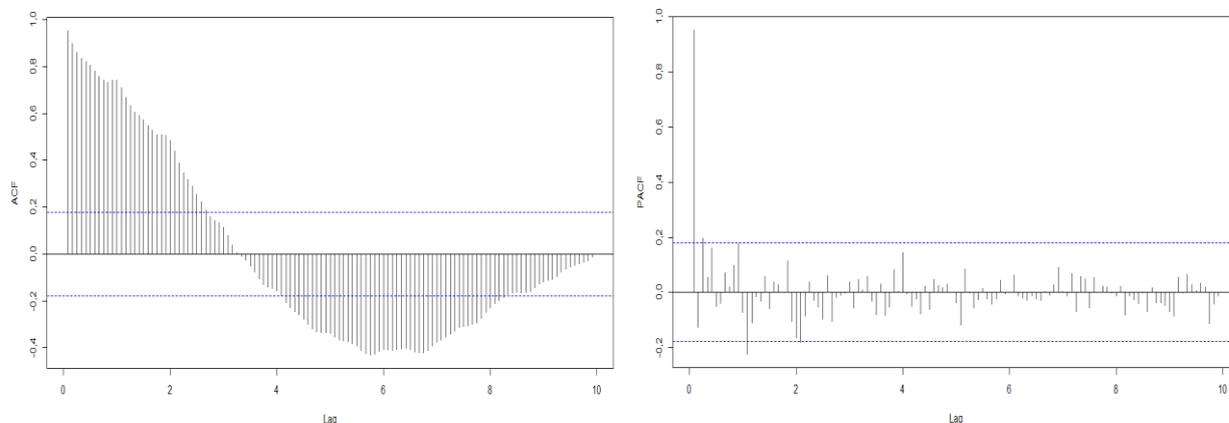
Figura 3 - Série temporal do consumo de energia elétrica no período de janeiro de 2007 a janeiro de 2016



Fonte: Elaboração Própria (2018)

Na figura 4, estão dispostas as funções autocorrelação (ACF) e de autocorrelação parcial (PACF). Com base no ACF da série observa-se um decaimento exponencial lento, já o PACF apresenta comportamento de decaimento rápido após o lag 1, o que sugere um padrão autorregressivo, apresentando poucos picos, além das extremidades que sugerem autocorrelação dos dados.

Figura 4. Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série original



Fonte: Elaboração Própria (2018)

Os resultados obtidos dos testes estatísticos para séries temporais (tabela 1) confirmam que a série apresentada não é estacionária, sendo necessário diferenciar a série para torná-la estacionária.

Tabela 1 - Testes de raiz unitária e autocorrelação da série original

Dickey-Fuller Aumentado	Estatística Calculada: 0,6992	Valor Crítico a 1%: -1,7048
Box-Pierce	Valor-p: 0,0000	

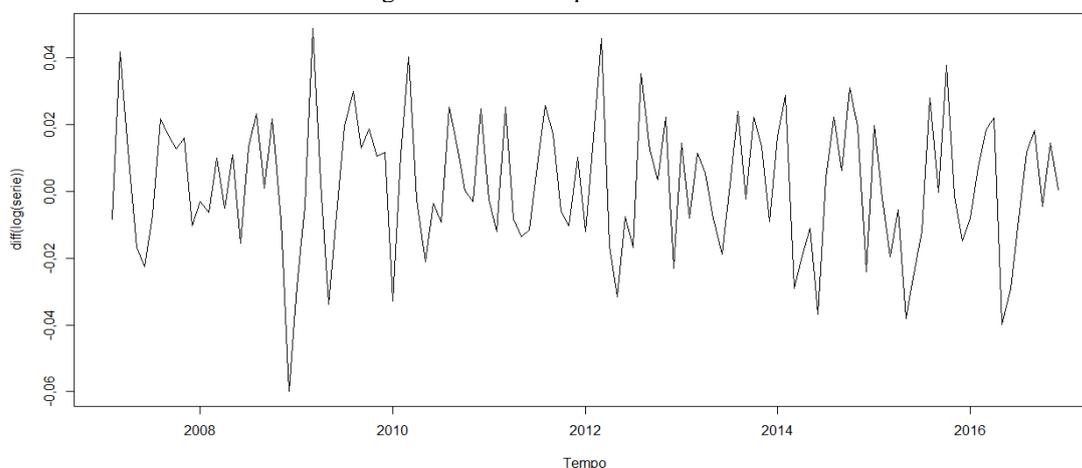
Fonte: Elaboração Própria (2018)

4.2. Série temporal transformada

Para remover a tendência e tornar a série estacionária, realizou-se a diferenciação de primeira ordem, que consiste em criar uma nova série agregando a diferença de uma observação atual da sua anterior. Contudo, esta abordagem para séries com grande amplitude numérica não é satisfatória para controlar a variância. A partir disso, aplicou-se o logaritmo à série original e depois a diferenciação. A série transformada corresponde a Figura 5.

É possível verificar que a série passou a assumir característica estacionária com a variância sob controle. Outro aspecto relevante da série transformada, é que esta admite um comprimento similar ao da série original, permitindo a verificação de picos mais elevados.

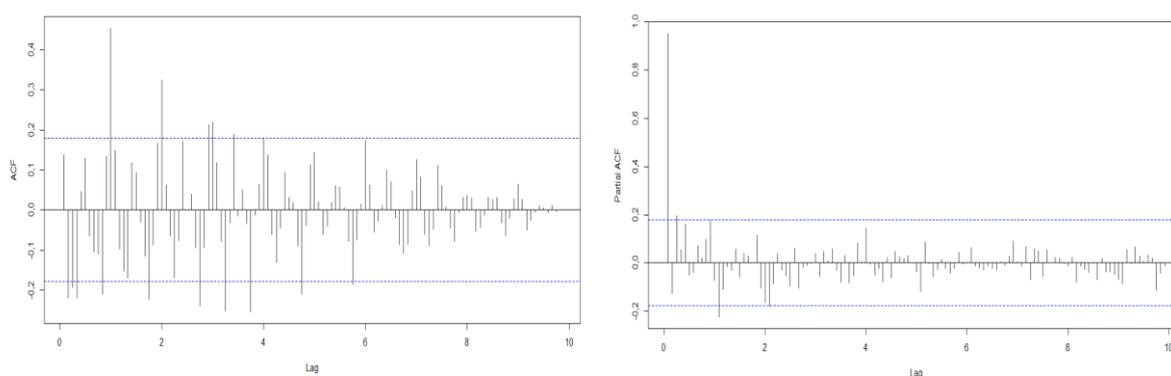
Figura 5 - Série temporal transformada



Fonte: Elaboração Própria (2018)

Os gráficos de autocorrelação e autocorrelação parcial evidenciaram o padrão de autoregressão e de médias móveis nos resíduos, conforme observado na figura 6. Observa-se a existência de picos fora da banda de significância; no gráfico da ACF há um pico significativo na lag 12, coerente com a estrutura dos dados mensais; já o gráfico da PACF mostrou picos estatisticamente significantes nas lag 1 e 12, sugerindo um modelo com padrão autorregressivo e com média móvel. Além disso, os picos além das bandas sugerem autocorrelação dos dados.

Figura 6 - Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série transformada



Fonte: Elaboração Própria (2018)

Os testes estatísticos (tabela 2) confirmaram que a série é não estacionária, logo não há necessidade da realização de outra diferenciação.

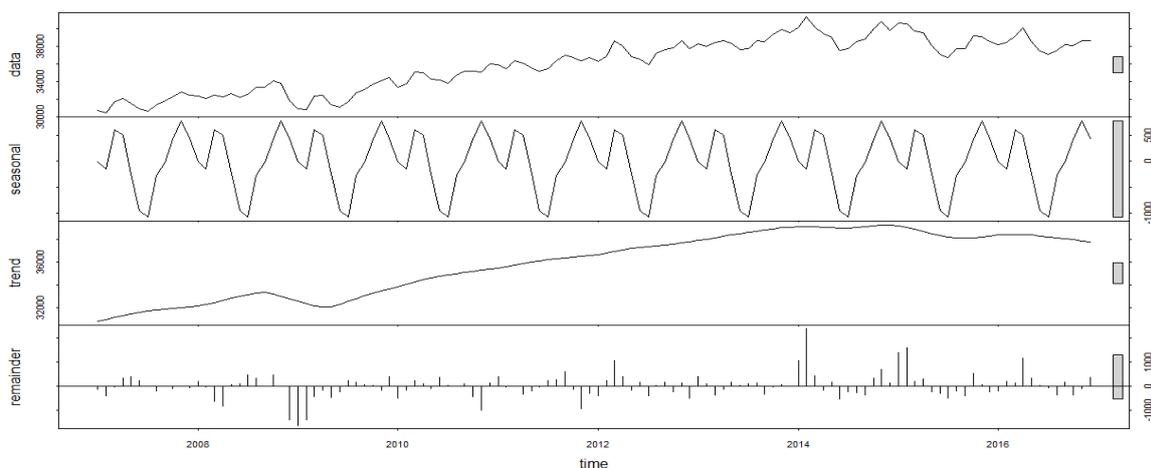
Tabela 2 - Testes de raiz unitária e autocorrelação da série transformada

Dickey-Fuller Aumentado	Estatística Calculada: 0,01	Valor Crítico a 1%: -6,1827
Box-Pierce	Valor-p: 0,1354	

Fonte: Elaboração Própria (2018)

Além disso, visando ratificar a confirmação de não estacionariedade, a série transformada foi decomposta, conforme figura 7, assim foi possível observar tendência e um padrão sazonal que variam entre períodos. Com base nessas características, o modelo a ser aplicado é o SARIMA, uma vez que contemplam as séries que apresentam autocorrelação sazonal.

Figura 7 - Decomposição da série CLL



Fonte: Elaboração Própria (2018)

4.3. Seleção do melhor modelo

Pela função *auto.arima* da biblioteca *'forecast'* se aplicado ao $\log(\text{serie})$ e sem aproximação, identifica-se o modelo $\text{ARIMA}(1,1,2)(1,0,1)$ [12], com Akaike Information Criterion de -626,28. Como esperado o modelo tem componente de integração 1, que representa a diferenciação de primeira ordem. Se aplicar a função *auto.arima* para $\text{diff}(\log(\text{serie}))$, encontra-se $\text{ARIMA}(1,0,2)(1,0,1)$ [12], com os mesmos parâmetros (Ver tabela 3).

A função *seas* realiza o ajuste do modelo através do algoritmo X-13 do Bureau de Censo Estatístico dos Estados Unidos e Canadá, ou do algoritmo SEATS (Signal Extraction in ARIMA Time Series) do Banco da Espanha, reunidos na biblioteca *'seasonal'*.

Tabela 3 - Comparativo entre modelos

Modelo	AICc
SARIMA (1,0,2)(1,0,1)[12]	-626,2900
X-13 (0,0,0)(0,1,1)	-559,5409
SARIMA (0,0,2)(2,0,0)[12] - dummy 2008	-625,4400
X-13 (3,0,1)(1,0,1) - dummy 2008	-624,9520
SARIMA (0,0,0)(2,0,0)[12] - dummy 2014	-620,2600
X-13 (0,0,0)(0,1,1) - dummy 2014	-611,1010
SARIMA (2,0,0)(2,0,0)[12] - dummy 2008 e 2014	-621,4700
X-13 (0,0,0)(0,1,1) - dummy 2008 e 2014	-559,5409

Fonte: Elaboração Própria (2018)

A função *auto.arima* apontou um modelo $\text{SARIMA}(1,0,2)(1,0,1)$ [12] com melhor ajuste, seguindo pelo mesmo modelo $\text{SARIMA}(0,0,2)(2,0,0)$ [12] com variável *dummy* representando a crise de 2008.

Figura 8 - Resíduos do modelo SARIMA

Fonte: Elaboração Própria (2018)

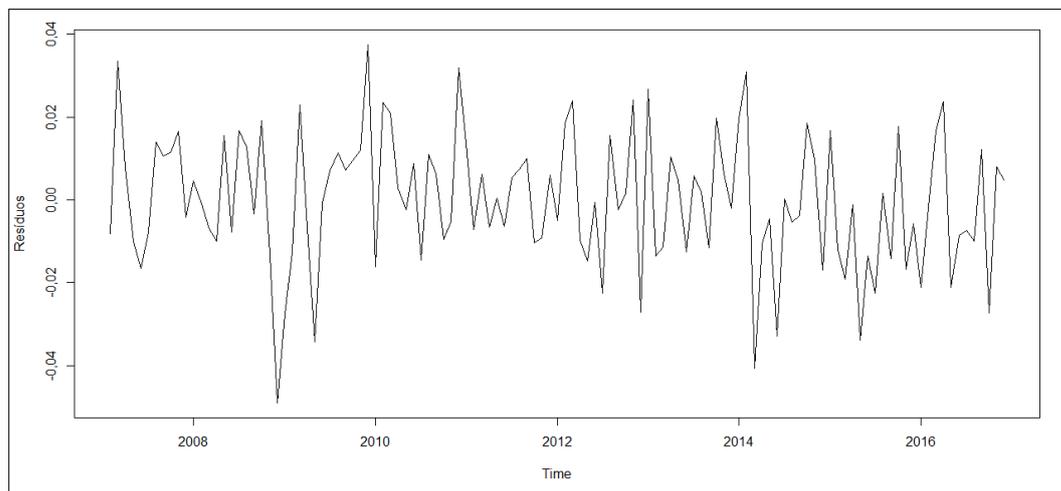
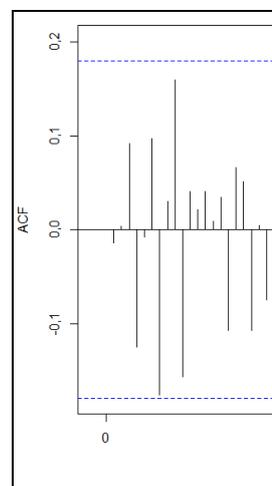
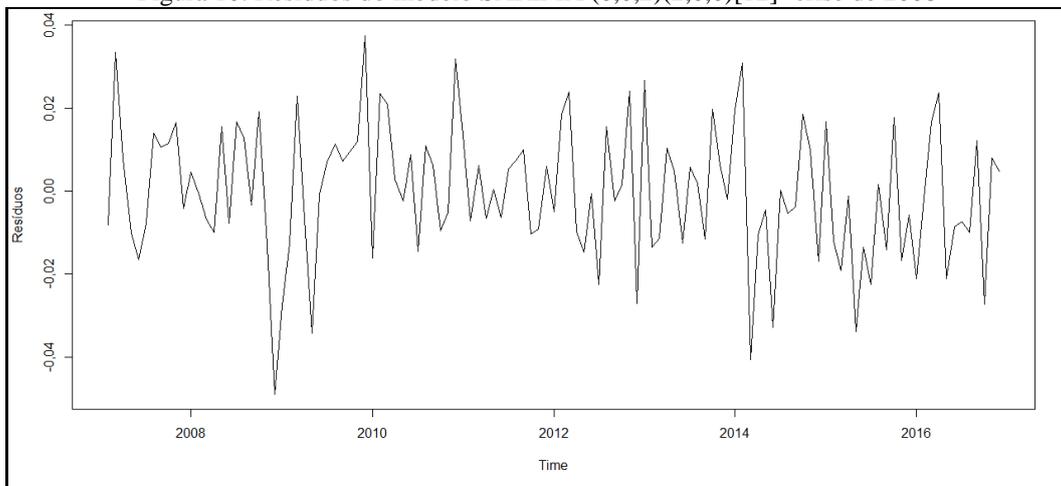


Figura 9 - ACF dos Resíduos SARI MA



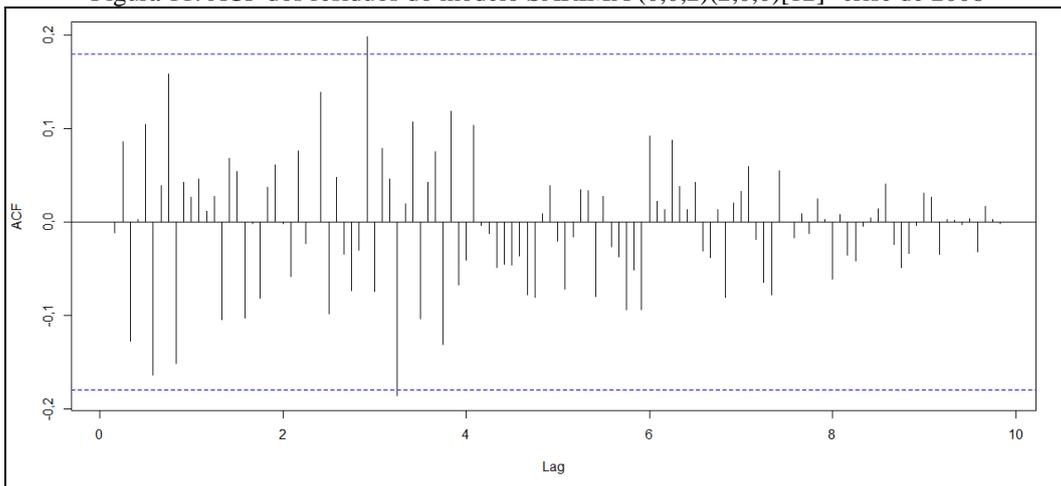
Fonte: Elaboração Própria (2018)

Figura 10. Resíduos do modelo SARIMA (0,0,2)(2,0,0)[12] -crise de 2008



Fonte: Elaboração Própria (2018)

Figura 11. ACF dos resíduos do modelo SARIMA (0,0,2)(2,0,0)[12] -crise de 2008

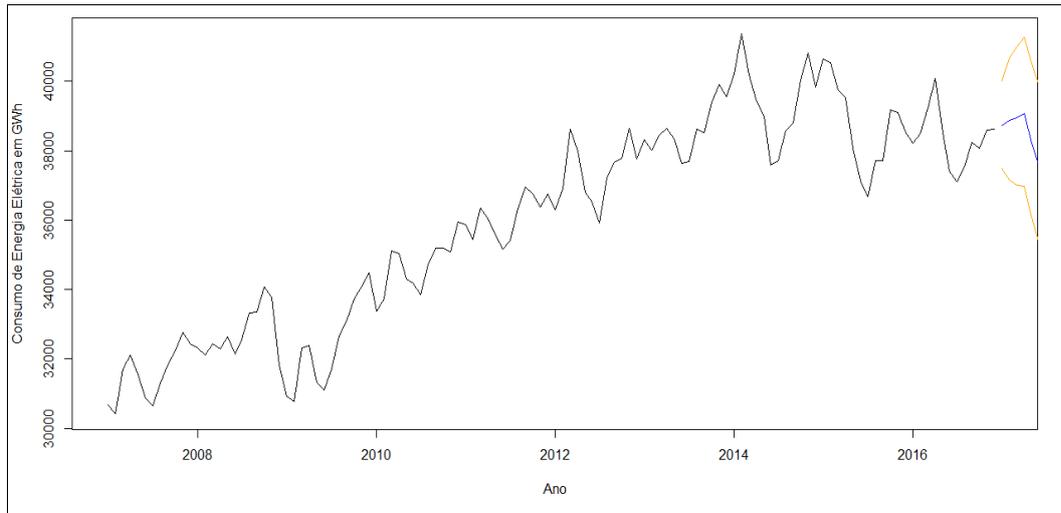


Fonte: Elaboração Própria (2018)

Pela análise dos resíduos, na Figura 8 e 10, os resíduos do modelo SARIMA apresentam bom controle da variância, no entanto, as Figuras 9 e 11 evidenciam a permanência de auto-correlação, o que sugere ordens mais altas de auto-regressão e médias móveis, que não foram testadas pelo padrão da função `auto.arima`.

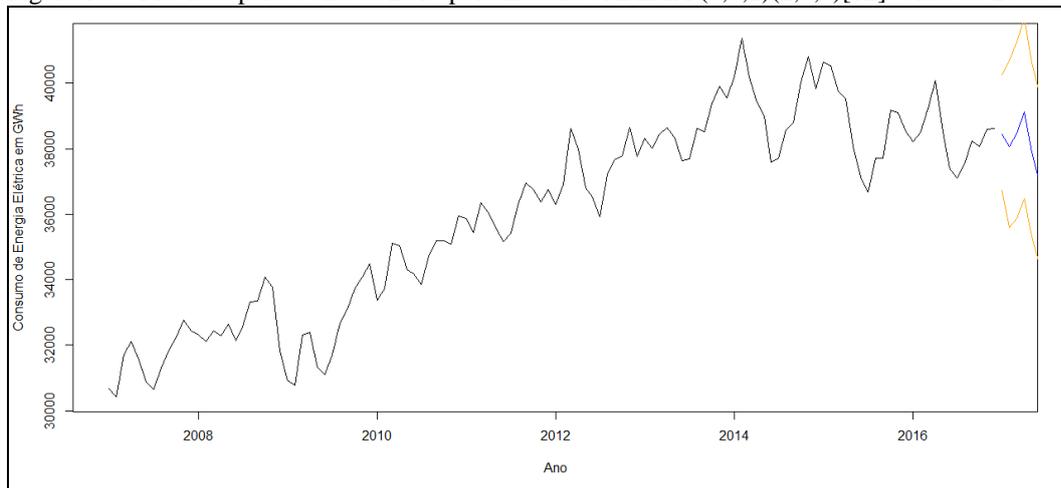
4.3 Previsão

Figura 12 - Previsão para o ano de 2017 pelo modelo SARIMA (1,0,2)(1,0,1)[12]



Fonte: Elaboração Própria (2018)

Figura 13 - Previsão para o ano de 2017 pelo modelo SARIMA (0,0,2)(2,0,0)[12] -crise de 2008



Fonte: Elaboração Própria (2018)

Para fazer a previsão, utiliza-se a função *predict* para o ano de 2017 e 2018, e os valores reais para calcular os erros. As Figuras 12 e 13 apresentam a previsão para os meses de janeiro a setembro de 2017 que, apesar de disponíveis, não foram utilizados na série para possibilitar a análise do erro do modelo. Na Figura 12 observa-se que os valores são mais baixos, enquanto na Figura 13 há presença de um pico.

Tabela 4 - Previsão para os dois modelos

Meses/Ano	SARIMA(1,0,2)(1,0,1)[12]			SARIMA(0,0,2)(2,0,0)[12] - crise 2008	
	Valor Real	ln do Valor Predito	Valor Predito	ln do Valor Predito	Valor Predito
Janeiro/2017	39138	10,5643	38727	10,55714	38451
Fevereiro/2017	38440	10,5678	38863	10,5468	38055
Março/2017	40241	10,57008	38952	10,55798	38483
Abril/2017	39070	10,57301	39066	10,57437	39119
Maió/2017	37912	10,55126	38226	10,54218	37880
Junho/2017	37745	10,53292	37531	10,51883	37006
Julho/2017	37084	10,52847	37364	10,5118	36747
Agosto/2017	37616	10,54256	37894	10,52203	37124
Setembro/2017	38741	10,54942	38155	10,53589	37643
Outubro/2017	-	10,55915	38528	10,53442	37587
Novembro/2017	-	10,56645	38811	10,54525	37997
Dezembro/2017	-	10,5606	38584	10,54476	37978
Janeiro/2018	-	10,56275	38667	10,54093	37833
Fevereiro/2018	-	10,56641	38809	10,53347	37552
Março/2018	-	10,56871	38898	10,54291	37908
Abril/2018	-	10,57144	39005	10,55651	38427
Maió/2018	-	10,55248	38272	10,52999	37421
Junho/2018	-	10,53647	37664	10,51076	36708
Julho/2018	-	10,53259	37519	10,50498	36497
Agosto/2018	-	10,54494	37985	10,51335	36804
Setembro/2018	-	10,55095	38214	10,52482	37228
Outubro/2018	-	10,55947	38541	10,52347	37178
Novembro/2018	-	10,56586	38788	10,53244	37513
Dezembro/2018	-	10,56074	38590	10,53209	37500

Fonte: Elaboração Própria (2018)

Com os valores da Tabela 4, o erro consiste na distância do valor predito ao valor real, de forma quadrática ou em módulo, ponderada ou não, segundo as diferentes fórmulas. Confirma-se juntamente com as figuras, na Tabela 5, que o modelo SARIMA(1,0,2)(1,0,1)[12] apresentou o menor erro em relação ao modelo SARIMA(0,0,2)(2,0,0)[12] - crise 2008.

Tabela 5 - Erros calculados para cada modelo

Erros	SARIMA(1,0,2)(1,0,1)[12]	SARIMA(0,0,2)(2,0,0)[12] - crise 2008
RQEMP	947,91	1359,46
EAMP	1291	1839
EAMPP	3,29%	4,69%

Fonte: Elaboração Própria (2018)

5 Conclusão

O objetivo deste estudo foi identificar um modelo que melhor se ajustasse a série temporal de consumo de energia elétrica por meio da metodologia *Box-Jenkins*. Primeiramente, criou-se uma Figura para verificar o comportamento dela, levando-se em conta a periodicidade dos dados. Em seguida, observou-se uma tendência crescente e um componente aparentemente sazonal, que depois foi confirmado por meio da decomposição da série.

Para remover a tendência e tornar a série estacionária, realizou-se a diferenciação de primeira ordem, que consistiu em criar uma nova série com a diferença de uma observação atual da sua anterior. Entretanto, esta abordagem para séries com grande amplitude numérica não foi suficiente para controlar a variância, então aplicou-se o logaritmo à série original e depois a diferenciação.

Os gráficos de autocorrelação e o de autocorrelação parcial identificaram o padrão de autoregressão e de médias móveis nos resíduos. Por fim, verificou-se que o modelo tem componente de integração 1, que representa a diferenciação de primeira ordem. Pelo AIC e pelos erros de previsão, o melhor modelo foi o SARIMA (1,0,2)(1,0,1)[12], o qual apresentou o menor erro dentre os outros modelos

Referências

BROOKS, C. Introductory Econometrics for Finance. Cambridge University Press. 3 ed. United Kingdom, 2014.

CARNEIRO, A. C. M. Previsão do consumo de energia elétrica a curto prazo, usando combinações de métodos univariados. 60p. Dissertação (Mestrado) -Universidade Federal de Juiz de Fora, Minas Gerais, 2014.

ELETOBRÁS. Relatório Anual 2016. Disponível em: <http://eletobras.com/pt/SobreaEletobras/Relatorio_Anuar_Sustentabilidade/2016/Relatorio-Anual-Eletobras-2016.pdf> Acesso em: 30.01.18.

EPE. Empresa de Pesquisa Energética. Resenha Mensal: o consumo de eletricidade apresenta o melhor resultado para o mês desde 2014. 2017. Disponível em: <<http://www.epe.gov.br/pt/imprensa/noticias/resenha-mensal-dezembro-2017>> Acesso em: 30.01.18.

GUJARATI, D. N.; PORTER, D. C. Econometria Básica. 5. ed. New York: The McGraw-Hill, 2011.

PINDYCK, R. S.; RUBENFIELD, D. L. Econometric Models and Economic Forecasts. New York, McGrawHill, 3rd Ed., 1991.

POKORNY, M. (1987). An Introduction To Econometrics. Nova York: Basil Blackwell, p. 343.

ROUMANI, Y.; NWANKPA, J. K; ROUMANI, Y. F. Time series modeling of vulnerabilities. Computers & Security, 51, 32 e 40, 2015.

SCHMIDT, C. A. J. & LIMA, M.A.M. A demanda por energia elétrica no Brasil. Revista Brasileira de Economia, 58:67–98, 2004.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. Revista eletrônica matemática e estatística em foco. Volume 1 - número 1, páginas: 57 a 66, 2013.

WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos box-jenkins na área de assistência técnica de computadores pessoais. *Gestão & Produção*, v.10, n.1, p.47-67, abr. 2003.