



# ConBRepro

X CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



EVENTO  
ON-LINE

02 a 04  
de dezembro 2020

## Previsão do Consumo de Energia Elétrica em um Prédio Público. Um Modelo ARIMA

**Edgar Noschang Kunz**

Mestrado PROFMAT - UFSC-Blumenau

**Hugo José Lara Urdaneta**

Departamento de Engenharia de Automação e Computação - UFSC-Blumenau

**Resumo:** No trabalho é apresentado um modelo de previsão do consumo de energia elétrica de um prédio público. Foi aplicada a abordagem Box Jenkins para selecionar o modelo ARIMA adequado e, depois, com tal escolha, estimar os seus parâmetros. O modelo resultante apresentou confiabilidade alta. Mostram-se algumas considerações teóricas, e uma descrição do processo de modelagem.

**Palavras-chave:** Séries temporais, Modelos ARIMA, Sazonalidade, Consumo de Energia elétrica.

## Electric Energy Consumption Forecasting in a Public Building. A ARIMA model

**Abstract:** In this work a model to forecast electric energy consumption in a public building is presented. The Box Jenkins approach was applied to choose a suitable ARIMA model, and then to build the model by estimating their parameters. The resulting model shows high confiability. Some theoretical considerations, and a description of the modeling process are included.

**Keywords:** Time Series, ARIMA Models, Seasonality, Electric Energy Consumption.

### 1. Introdução

Dados obtidos das observações coletadas sequencialmente no tempo são extremamente comuns. Em Finanças, observamos taxas de juros semanais, preços de fechamento diários das ações, índices de preços mensais, vendas anuais, e assim por diante. Em meteorologia, observamos temperaturas baixas e altas cada dia, precipitações anuais, e índices de seca. Em agricultura coletamos os números anuais para produção de gado e colheitas, erosão do solo e exportações. Em ciências Biológicas, observamos a atividade elétrica do coração em intervalos de milissegundos. Em ecologia, estudamos da abundância de espécies de animais. A lista de áreas nas quais séries de tempo são estudadas é virtualmente infinita.

O propósito da análise de séries de tempo em geral se evidencia de duas formas: entender ou modelar o mecanismo estocástico que gera a série observada e prever ou

antecipar valores futuros da série, com base nos dados históricos e, possivelmente outras séries ou fatores relacionados (CRYER; CHAN, 2008).

A administração eficiente da energia é extremamente importante. Existem muitos benefícios que podem derivar de uma descrição acurada e a previsão do consumo de energia. O provedor de energia requer que um consumidor grande de energia possa declarar sua necessidade para um período determinado de tempo. O segundo benefício é econômico: o custo da energia extra de um valor estabelecido é muito mais grande que o primário. Pedidos incorretos levam a perdas econômicas para a companhia consumidora. O terceiro é a habilidade de usar o modelo para o desenvolvimento de estratégias de administração do recurso consumido (TEPEDINO et al, 2014).

Previsão do consumo de eletricidade em prédios de universidades tem sido estudado: Em Lee et al (2018), foram usadas ferramentas para análise de séries temporais, como Médias Móveis Simples e ponderadas (SMA, WMA), Alisamento Exponencial Simples (SES), Tendência Holt Linear (HL), Holt Winters (HW) e Médias Móveis Centradas (CMA) para estudar o consumo de eletricidade em prédios universitários em Malásia. Dados diários de consumo de energia por 5 anos de 2 prédios universitários em Londres foram usados para estabelecer modelos, usando Regressão Múltipla (MR) em Amber et al (2017), entre outros. Estudos que estabelecem modelos para consumo de energia em prédios (NOH; RAJAGOPAL, 2013), usando séries de tempo para previsão de curto termo, e processos Gaussianos não paramétricos para longo termo; ou modelos para consumo de energia em sistemas de transporte elétrico (TEPEDINO et al, 2014), entre muitos outros exemplos, mostram que o assunto é de interesse, e tem sido estudado amplamente.

Desde o ponto de vista da estatística, a modelagem de séries de tempo, usando os modelos ARIMA, é um processo de inferência onde devem ser estimados tanto os parâmetros que ajustam o modelo, quanto o próprio modelo. Isto é, o processo de modelagem estabelece uma estratégia para escolher, entre as múltiplas possibilidades que oferecem os modelos ARIMA, um bom modelo estimando os parâmetros  $p$ ,  $q$  e  $d$ . Uma vez que tal escolha é feita, e o modelo fixado, o próximo passo da inferência é a estimação dos parâmetros (coeficientes) do modelo ARIMA resultante. Sendo uma escolha combinatória, a fixação do modelo é um processo difícil, e que pode oferecer múltiplos resultados possíveis.

Neste artigo usamos a chamada abordagem Box-Jenkins para estimar o modelo ARIMA sobre o consumo de energia elétrica em um prédio público, cujo objetivo é prever com boa acuracidade os valores futuros dessa grandeza para uma administração eficiente.

Como será estudado, podemos encontrar um modelo ARIMA quando a série analisada é estacionária e não sazonal. A sazonalidade é tratada decompondo a série original e depois lhe restando o fator sazonal, o que resulta em uma série estacionária. Adicionalmente à escolha do modelo, a tarefa da análise envolve a validação do modelo.

O remanente do artigo está organizado como segue: Na próxima seção descrevemos brevemente os conceitos referentes às séries de tempo, e os modelos ARIMA. Na seção 3 descrevemos a decomposição da série, a remoção do fator sazonal e a abordagem Box-Jenkins. Depois na seção 4 mostramos o caso de estudo, analisando a série de tempo do consumo de Energia elétrica de um prédio da UFSC em Blumenau, SC. Finalizamos na seção 5 com algumas conclusões do trabalho.

## **2. Séries de tempo e modelos ARIMA**

Muitas das ideias e conceitos básicos apresentados nesta seção podem ser encontrados

em fontes básicas como Morettin e Bussab (2013), ou Cryer e Chan (2008). Uma série temporal é uma das infinitas possíveis realizações do processo estocástico. Por isso, há infinitas possibilidades de séries temporais. Para Krolzig (2002), dados um espaço amostral  $\Omega$ , um conjunto de índices  $\Gamma$ , que pode ser o conjunto dos números naturais, ou bem o conjunto dos inteiros.

Definimos como *processo estocástico (discreto) à função de valor real*  $X: \Gamma \times \Omega \rightarrow R$ , tal que para cada  $t \in \Gamma$ , e  $\omega \in \Omega$ ,  $X_t(\omega)$  é uma variável aleatória. Algumas vezes denotamos processo estocástico por  $\{X_t(\omega)\}_{t \in \Gamma}$ , ou simplificada por  $\{X_t\}_{t \in \Gamma}$ . As séries temporais são definidas a partir dos processos estocásticos: Uma série temporal  $\{x_t\}_{t=0}^T$  é (a parte finita de) uma realização particular de um processo estocástico. A série temporal é usualmente denotada por  $x_t$ , e dizemos que foi gerada pelo processo estocástico subjacente.

Desde o ponto de vista teórico, a análise da série temporal origina-se desde as distribuições conjuntas de probabilidade para o processo estocástico. No entanto, para objetivos práticos, tais distribuições de probabilidade nem sempre estarão disponíveis. O objetivo de analisar a série temporal deve ser feito desde as informações aportadas pelos dados. Para tal fim, as ferramentas disponíveis serão os primeiros e segundos momentos do processo estocástico associado. Os primeiros momentos, as médias, geram a série  $\{\mu_t\}_{t \in \Gamma}$ , onde  $\mu_t = E(X_t)$ , enquanto os segundos momentos produzem a função de autocovariância, dada para os índices  $t$  e  $h$ , e os processos  $\{X_t\}_{t \in \Gamma}$  e sua defasagem  $\{X_{t-h}\}_{t \in \Gamma}$ , por  $\gamma_t(h) = Cov(X_t, X_{t-h}) = E[(X_t - \mu_t)(X_{t-h} - \mu_{t-h})]$ . Note que  $\gamma_t(0) = Var(X_t)$  é a variância de  $X_t$ . A estimação desses momentos requer o conhecimento das distribuições conjuntas para as variáveis aleatórias que conformam o processo  $\{X_t\}_{t \in \Gamma}$ . Com base na série de autocovariância, define-se também a *função de autocorrelação*, por

$$\rho_t(h) = \frac{\gamma_t(h)}{\sqrt{\gamma_t(0)\gamma_{t-h}(0)}} = \frac{\gamma_t(h)}{\sqrt{Var(x_t)Var(x_{t-h})}}$$

A autocorrelação indica o grau de associação linear entre  $X_t$  e  $X_{t-h}$ . É fácil provar que  $-1 \leq \rho_t(h) \leq 1$ . Se tal valor aproxima-se a -1, então temos uma associação linear negativa entre  $\{X_t\}_{t \in \Gamma}$  e sua  $h$ -ésima defasagem  $\{X_{t-h}\}_{t \in \Gamma}$ ; a proximidade a 1 indica associação linear positiva e quando o valor da autocorrelação é aproximadamente nula, então a associação é também aproximadamente nula.

Para fazer inferências acerca da estrutura de um processo estocástico com base em observações tomadas do processo, usualmente devemos tomar algumas simplificações e suposições acerca da sua estrutura. A mais importante de tais suposições é a *estacionariedade*. A ideia básica da estacionariedade é que as leis de probabilidade que governam o processo não mudam no tempo. Um processo  $\{X_t\}_{t \in \Gamma}$  é dito *estritamente estacionário* se a distribuição conjunta das variáveis aleatórias que conformam  $\{X_t\}_{t \in \Gamma}$  coincidem com as distribuição conjunta de  $\{X_{t-h}\}_{t \in \Gamma}$  para todas as escolhas da defasagem  $h$ . Como consequência dessa definição podemos ver que para cada par de índices  $t$  e defasagem  $h$ ,  $E(X_t) = E(X_{t-h})$ ,  $Var(X_t) = Var(X_{t-h})$  e

$$\gamma_t(h) = Cov(X_t, X_{t-h}) = Cov(X_0, X_h).$$

Simplificando a notação, escrevemos  $\gamma(h) = \gamma_t(h)$ , e  $\rho_t(h) = \rho(h)$ . Assim, se o processo é estritamente estacionário, e tem variância finita, então a função de covariância depende somente da defasagem do tempo. Um processo estocástico  $\{X_t\}_{t \in \Gamma}$  é dito *fracamente estacionário* se a função média é constante no tempo, e se  $\gamma_t(h) = \gamma_0(t-h)$ . Se um processo é estritamente estacionário, então ele é também fracamente estacionário. Usaremos esta última definição neste artigo.

Os conceitos dos momentos são paramétricos, no sentido que suas definições são abstratas, desde as distribuições de probabilidade. As informações em relação aos momentos virão através dos seus estimadores: os momentos amostrais. Assim, com base na série de tempo observada, os momentos amostrais são dados por  $\underline{y} = T^{-1} \sum_{t=1}^T y_t$ , e  $\hat{\gamma}_h = T^{-1} \sum_{t=h+1}^T (y_t - \underline{y})(y_{t-h} - \underline{y})$  para a média e as auto covariâncias amostrais, respectivamente. As correlações e auto correlações parciais são dadas por:  $\hat{\rho}_h = \hat{\gamma}_h / \hat{\gamma}_0$  e  $\alpha_h^{(h)} = Corr(y_t, y_{t-h} | y_{t-1}, \dots, y_{t-h+1})$ .

## Modelos ARIMA

Um modelo estatístico pode ser visto como uma simplificação, sob suposições adequadas, de um fenômeno observável, que visa replicar, ou fazer previsões sobre aquele fenômeno. Observações particulares (amostras) são usadas para construir o modelo, através de estimadores dos seus parâmetros. Nosso caso destaca as séries temporais como observações que vão ser úteis na construção do modelo, cujos parâmetros são os do processo estocástico subjacente. Existem inúmeras possibilidades diferentes para definir modelos que aproximem séries temporais, e o sucesso de cada um depende na adequação de suas características em relação às particularidades da série.

Os modelos ARIMA são opções populares, e muito versáteis na tarefa de propor modelos aptos para previsão usando séries temporais. O termo ARIMA é uma composição de siglas: AR indica que a variável evolutiva de interesse é *regressada* de suas próprias defasagens (modelo autorregressivo), enquanto a parte MA indica que os erros de regressão são uma combinação linear dos termos de erro cujos valores ocorreram no tempo atual, e várias defasagens atrás no passado. O I (por integrado) indica que uma transformação de diferenças tem sido executada, possivelmente várias vezes. O objetivo de cada uma dessas características é fazer que o modelo seja ajustado o mais próximo possível aos dados coletados. Os modelos ARIMA aplicam a processos lineares:

Um **processo linear**  $\{x_t\}$  é uma representação por uma combinação linear ponderada dos termos de ruído branco  $\{\varepsilon_t\}$  entre os momentos do tempo analisado:

$$x_t = \sum_{j=-\infty}^{\infty} \psi_j \varepsilon_{t-j} = \Psi(L) \varepsilon_t$$

Usamos a notação compacta  $\Psi(L) = \sum_{j=-\infty}^{\infty} \psi_j L^j$  para o filtro linear, com  $L^j$  o operador de atraso de ordem  $j$ . Baseado na decomposição de Wold (ver, por exemplo, Krolzig (2002)), Qualquer processo estocástico de média zero e auto covariância estacionária pode ser representado por um modelo linear. Se  $x_t$  é um processo linear, então existe algum  $\hat{x}_t$  estacionário que representa  $x_t$  (MORETTIN; TOLOI, 2006). Logo, a condição para que a estimação de uma série temporal seja válida usando modelos ARIMA é existência da estacionariedade de seus resíduos.

Seja  $x_t$  uma série que segue um modelo autorregressivo, integrado e de médias móveis, que denominamos ARIMA(p,d,q) com  $p$  a ordem de  $\alpha(L)$ ,  $q$  a ordem de  $\beta(L)$  e  $d$  a ordem d-ésima diferença da série  $x_t$ , é determinado por  $\alpha(L) \Delta^d x_t = \beta(L) \kappa_t$ , com  $\kappa_t$  os resíduos.

A condição de estacionariedade do processo linear pode ser verificada se satisfaz  $|\alpha| < 1$ . Outra condição é a invertibilidade do processo linear, que satisfaz  $|\beta| < 1$ .

Assim, pode-se ter variações para o modelo ARIMA(p,d,q) de acordo com os valores dos parâmetros  $p, d, q \in Z_+$ . Por exemplo, se  $d = 0$ , então se tem ARMA(p,q); se  $d = 0$  e  $q = 0$ , então é AR(p); e se  $d = 0$  e  $p = 0$ , segue que trata-se de MA(q).

### 3. Abordagem Box-Jenkins

A abordagem Box-Jenkins é uma metodologia que ajusta modelos ARIMA a um conjunto de dados (MORETTIN; TOLOI, 2006). A construção do modelo baseia-se em um ciclo iterativo sob observação dos próprios dados da série. Esse ciclo iterativo atende às ações do Fluxograma 1 que ilustra a liberdade nas iterações.

Fluxograma 1 – Ciclo iterativo da abordagem Box-Jenkins



Fonte: Elaborado pelo autor

A primeira fase é a identificação. Nela são apuradas as funções de autocorrelação (FAC) e as funções de autocorrelações parciais (FACP). A partir disso são observados os *lags* ou instantes no tempo considerados com valores significativamente relevantes de FAC ou FACP. O objetivo é determinar as características quanto à estacionariedade e à sazonalidade da série.

Se apresentar comportamento senoidal no correlograma da FAC e a decomposição do fator sazonal se mostrar perfeitamente previsível no tempo, tem-se uma série sazonal determinística. Se apresentar senoides e o fator sazonal ainda variar no tempo, então é sazonal estocástica. Se não apresentar senoides, a série não apresenta sazonalidade.

Nos correlogramas de FAC e FACP, o decaimento exponencial indica que a série é estacionária, assim como no caso de senoides amortecidos. Porém, um decaimento diferente disso, deve-se considerar característica de não estacionariedade. O Teste de Ljung-Box permite observar com maior precisão se os resíduos da série comportam-se como ruído branco, ou seja, autocorrelações nulas, portanto nenhum *lag* deve apresentar FAC ou FACP significativamente diferente de zero para o teste indicar estacionariedade.

Nas fases de estimação e verificação, os *lags* dos correlogramas FAC e FACP indicados como significativamente diferentes de zero da série original, são equivalentes aos  $p$  e  $q$  candidatos para o modelo ARIMA( $p,q$ ). Então, todas as combinações possíveis para esses candidatos, incluindo  $p = 0$  e  $q = 0$ , devem ser apuradas para modelos candidatos. O modelo, dentre os candidatos, que apresentar os melhores valores nos critérios de informações, é considerado o modelo que estima a série temporal. O modelo final

ajustado é obtido quando o modelo que estima a série temporal apresenta resíduos que se comportam como ruído branco.

A fase de previsão permite que a série seja projetada para instantes futuros, isso utilizando o modelo final ajustado como o objeto matemático que representa a série temporal estudada.

#### 4. Caso de estudo

Para a previsão de um caso real de série temporal sobre o consumo de energia elétrica, foram tomados os registros do prédio acadêmico da UFSC em Blumenau. Os valores em kWh são computados pela companhia de distribuição de energia na região e, apesar de contínuos, apresentam-se em números inteiros conforme a Tabela 1. As análises foram executadas no software EViews® na sua versão estudantil.

**Tabela 1 – Consumo energia elétrica prédio acadêmico UFSC Blumenau.**

Mês	2015	2016	2017	2018	2019	2020
janeiro		9027	8302	10559	15252	13651
fevereiro		9225	14491	20705	16492	15465
março		13076	21196	25213	25000	
abril		13554	17262	24746	24614	
maio		9891	18249	16101	18508	
junho		11069	15174	13981	16108	
julho		8018	9904	10023	11422	
agosto		9864	16540	16207	15850	
setembro		11996	17362	19405	18211	
outubro		13943	18454	18485	22273	
novembro		15175	18686	21413	21955	
dezembro	10606	9746	11898	12969	12117	

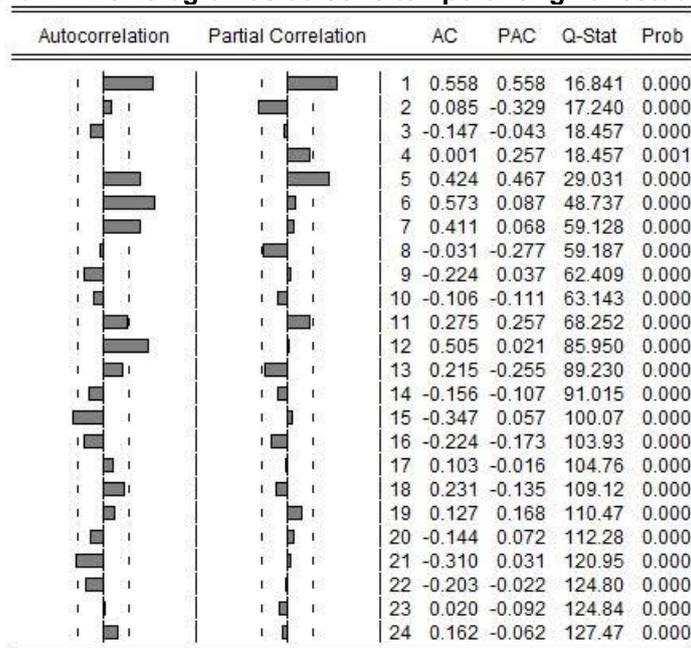
Fonte: elaborado pelo autor

O interesse nesse estudo em particular é encontrar os valores máximos aceitáveis para o consumo de energia elétrica do caso, isto é, aqueles que não seriam considerados desperdício. Após encontrar esses valores, a administração da instituição irá poder comparar o máximo valor previsto com o realizado em cada um dos meses que se sucederem e decidir sobre as ações para minimizar os possíveis desperdícios.

Seja  $X_t$  a série temporal original da variável aleatória  $X$  realizada em cada  $t$  para cada um dos meses. A amostra para essa série temporal inicia em dezembro de 2015 e termina em fevereiro de 2020, logo  $t \in T = \{1, \dots, 51\}$ .

Para caracterizar a série estudada, adotamos a abordagem Box-Jenkins e, na fase inicial, podemos visualizar que os correlogramas, conforme a Figura 2, que indicam senoides em FAC. Para certificar a suspeita de sazonalidade, utiliza-se o método Census X-12, e podemos construir os gráficos na Figura 3 com as decomposições da série.

**Figura 2 – Correlogramas da série temporal original estudada**



Fonte: elaborado pelo autor no EViews®

Verifica-se, na Figura 3, que há sazonalidade determinística, pois as repetições são perfeitas em 12 meses no gráfico do fator sazonal. Tomando a série sem a sazonalidade, ou seja, a série ajustada sazonalmente, o resultado de seus resíduos aponta correlação diferente de zero em 10 lags, com correlograma do FAC em decaimento não exponencial conforme a Figura 4, logo, essa é não estacionária.

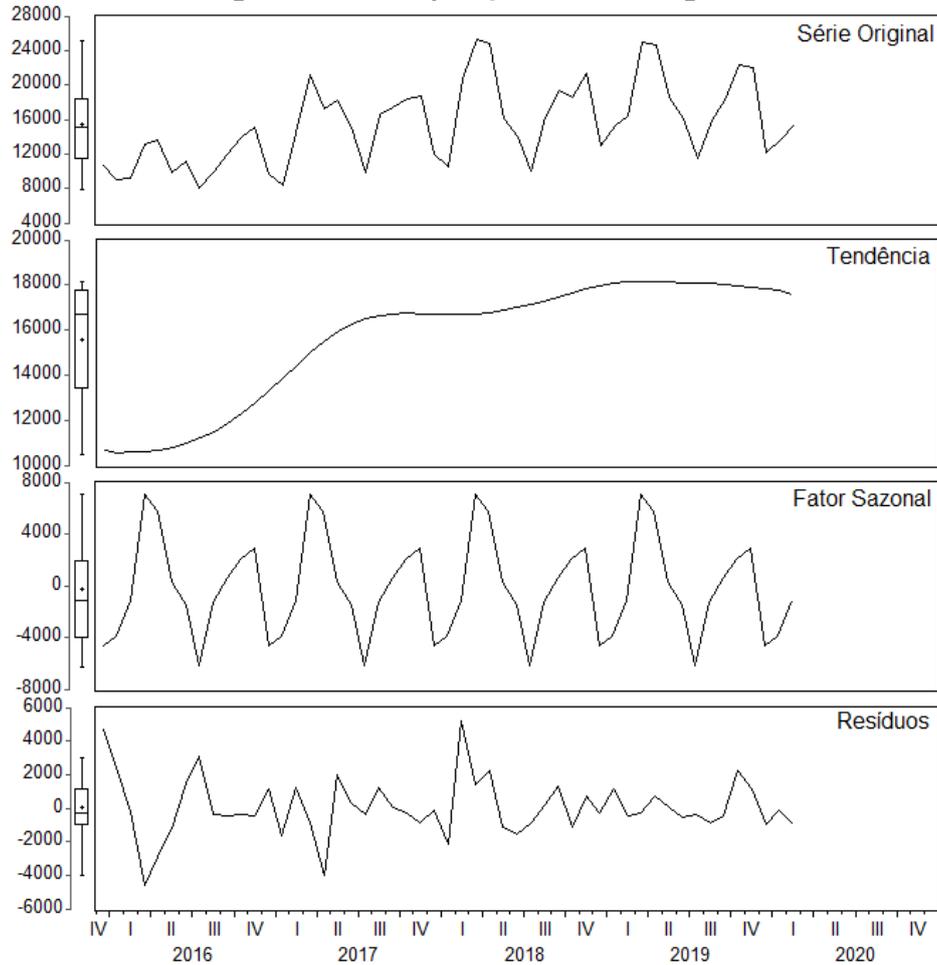
Para estimar o modelo de uma série sazonal determinística não estacionária precisa-se eliminar a tendência e, após a regressão exponencial de segundo grau, notou-se que a estacionariedade foi alcançada e os valores dos critérios de informação foram melhores que na regressão linear. Portanto, a série sazonalmente ajustada foi ainda ajustada exponencialmente, que denominamos  $\hat{X}_t$ .

A partir de então, tomam-se os parâmetros candidatos para  $p$  e  $q$  observados nos correlogramas da série original, também evidentes na Figura 1. As correlações significativas adotadas para determinar os parâmetros candidatos para o modelo foram consideradas nos lags {1, 5, 6, 12}. Portanto, foram apurados os valores para os critérios de informação para todas as combinações possíveis para esses lags, onde se observaram os melhores resultados na Tabela 2.

Conforme a Tabela 2,  $R^2$  foi melhor para o modelo ARMA(1,12), porém, AIC e BIC foram melhores para o modelo ARMA(6,12). Antes de verificar os resíduos de ambos os modelos, percebe-se que o valor de  $\beta$  é (-1) na estimação ARMA (6,12), portanto esse é um modelo não invertível que pode ser descartado esse candidato que não se aplica a processos lineares.

Assim, o modelo escolhido foi o ARMA(1,12) para estimar a série temporal. A Figura 5 mostra que os resíduos são ruído branco e a Figura 6 as estatísticas dessa estimação final, portanto a série temporal do modelo final estimado, denominada  $Y_t$ , é a série  $\hat{X}_t$  ajustada por ARMA(1,12).

**Figura 3 – Decomposição da série original**



Fonte: elaborado pelo autor no EViews®

**Figura 4 – Correlogramas da série sazonalmente ajustada**

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.752	0.752	30.583	0.000	
2	0.664	0.227	54.933	0.000	
3	0.546	-0.028	71.693	0.000	
4	0.461	-0.000	83.930	0.000	
5	0.485	0.242	97.740	0.000	
6	0.471	0.079	111.07	0.000	
7	0.432	-0.070	122.51	0.000	
8	0.341	-0.150	129.83	0.000	
9	0.316	0.110	136.27	0.000	
10	0.210	-0.150	139.18	0.000	
11	0.189	-0.022	141.59	0.000	
12	0.145	-0.047	143.05	0.000	
13	0.110	0.019	143.92	0.000	
14	0.072	-0.078	144.30	0.000	
15	-0.015	-0.146	144.32	0.000	
16	-0.064	-0.034	144.64	0.000	
17	-0.099	0.060	145.42	0.000	
18	-0.080	0.055	145.95	0.000	
19	-0.043	0.102	146.10	0.000	
20	-0.025	0.028	146.15	0.000	
21	-0.079	-0.109	146.72	0.000	
22	-0.152	-0.135	148.88	0.000	
23	-0.208	-0.051	153.06	0.000	
24	-0.236	-0.008	158.64	0.000	

Fonte: elaborado pelo autor no EViews®

**Tabela 2 – Critérios de informação dos modelos candidatos ARMA( $p,q$ )**

p	q	$R^2$	AIC	BIC
1	12	0,892922	18,16844	18,81238
6	12	0,891362	18,16041	18,80435

Fonte: elaborado pelo autor

Pode-se observar no gráfico representado na Figura 7 o quanto a série ajustada final se aproxima da série original e os resíduos num comportamento adequado de ruído branco, indicando que trata-se mesmo de uma boa estimação.

Ao apurar a acuracidade de  $Y_t$  em relação a  $X_t$ , se obtém  $MAPE = 9,81\%$ , que confirma a acuracidade do modelo. Além disso, o próprio valor de  $R^2$  aponta que 89,3% da variabilidade do percentual de  $X$  pode ser atribuída a tendência do modelo.

Os valores previstos podem ser extraídos do arquivo gerado pelo EViews® e plotados em gráfico com limites de previsão de dois desvios padrões para mais e para menos ( $\pm 2S.E.$ ), conforme a Figura 8, até o final de 2020, como queríamos realizar. Assim, a administração dessa instituição pode utilizar o modelo para reduzir seus desperdícios em energia elétrica a medida que as realizações futuras ultrapassarem os valores máximos previstos.

**Figura 5 – Resíduos de  $Y_t$**

Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	
		1	-0.026	-0.026	0.0370	
		2	-0.067	-0.067	0.2829	
		3	-0.265	-0.270	4.2335	0.040
		4	-0.280	-0.329	8.7271	0.013
		5	0.058	-0.042	8.9221	0.030
		6	0.223	0.122	11.908	0.018
		7	0.204	0.106	14.459	0.013
		8	-0.153	-0.210	15.925	0.014
		9	-0.004	0.090	15.926	0.026
		10	-0.195	-0.034	18.433	0.018
		11	0.054	0.050	18.631	0.029
		12	0.117	0.002	19.584	0.033
		13	0.046	-0.004	19.734	0.049
		14	0.108	0.143	20.589	0.057
		15	-0.233	-0.164	24.681	0.025
		16	-0.134	-0.171	26.062	0.025
		17	-0.018	0.030	26.089	0.037
		18	0.006	-0.120	26.091	0.053
		19	0.091	-0.106	26.796	0.061
		20	0.216	0.145	30.866	0.030
		21	0.023	0.127	30.915	0.041
		22	-0.074	0.080	31.427	0.050
		23	-0.024	0.018	31.481	0.066
		24	-0.305	-0.236	40.823	0.009

Fonte: elaborado pelo autor no EViews®

**Figura 6 – Estatísticas de  $Y_t$**

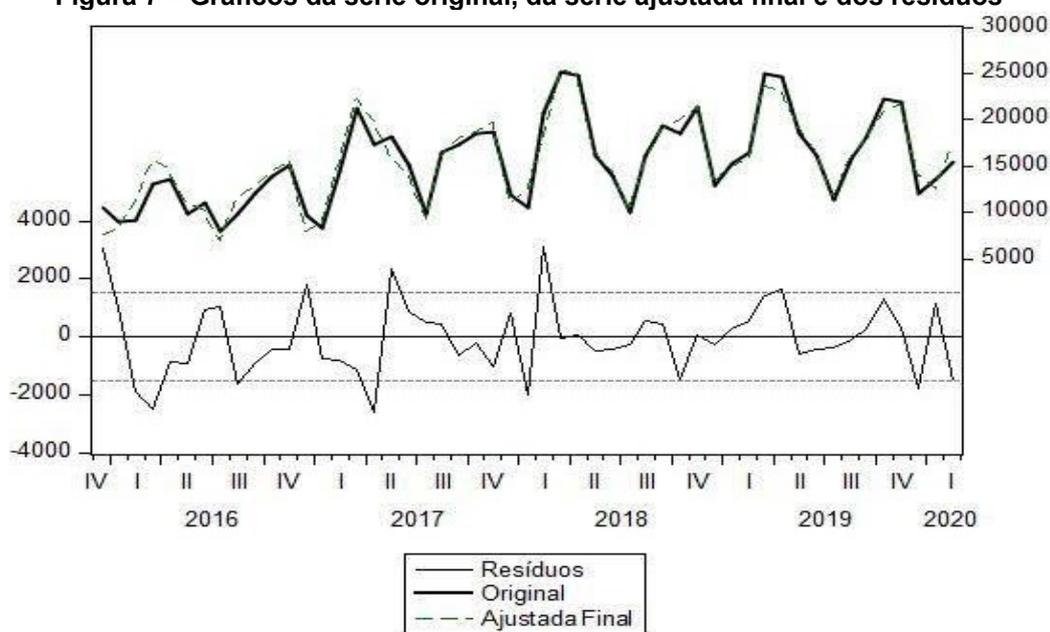
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6026.745	654.1722	9.212781	0.0000
@TREND	398.0211	83.00675	4.795045	0.0000
@TREND^2	-5.061540	1.773635	-2.853767	0.0073
@MONTH=1	-308.9710	448.9975	-0.688135	0.4960
@MONTH=2	4145.612	432.8319	9.577881	0.0000
@MONTH=3	10027.53	577.7016	17.35763	0.0000
@MONTH=4	8626.153	585.7363	14.72702	0.0000
@MONTH=5	4232.573	689.5764	6.137932	0.0000
@MONTH=6	2279.809	1002.468	2.274196	0.0294
@MONTH=7	-2180.297	1281.100	-1.701894	0.0979
@MONTH=8	2788.999	1164.859	2.394281	0.0223
@MONTH=9	4785.543	1232.244	3.883599	0.0005
@MONTH=10	5981.912	708.2513	8.446030	0.0000
@MONTH=11	7186.259	854.1516	8.413330	0.0000
AR(1)	0.341376	0.149748	2.279670	0.0290
MA(12)	-0.999995	5734.189	-0.000174	0.9999
SIGMASQ	1578611.	4.69E+09	0.000337	0.9997

R-squared	0.927187	Mean dependent var	15479.08
Adjusted R-squared	0.892922	S.D. dependent var	4702.544
S.E. of regression	1538.804	Akaike info criterion	18.16844
Sum squared resid	80509152	Schwarz criterion	18.81238
Log likelihood	-446.2952	Hannan-Quinn criter.	18.41451
F-statistic	27.05931	Durbin-Watson stat	1.901627
Prob(F-statistic)	0.000000		

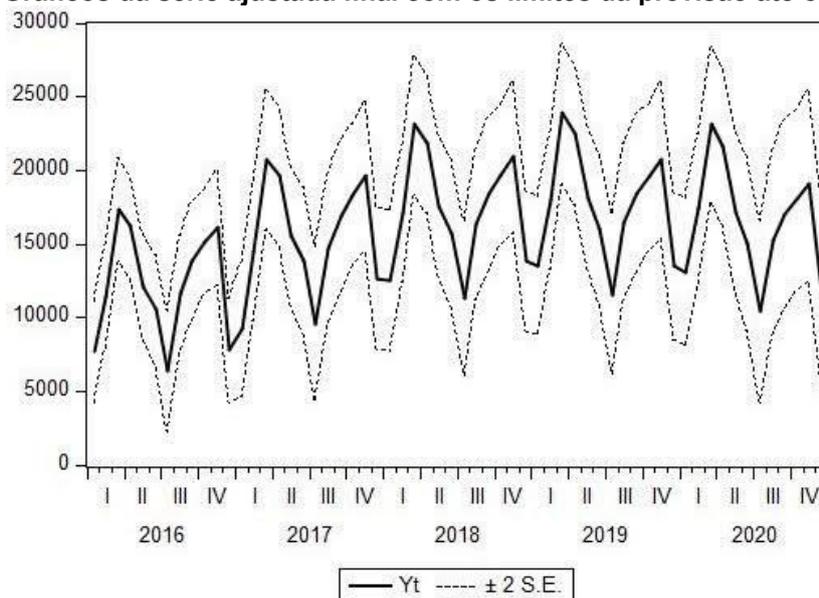
Fonte: elaborado pelo autor no EViews®

**Figura 7 – Gráficos da série original, da série ajustada final e dos resíduos**



Fonte: elaborado pelo autor no EViews®

Figura 8 – Gráficos da série ajustada final com os limites da previsão até o fim de 2020



Fonte: elaborado pelo autor no EViews®

## 5. Comentários finais

Os meios utilizados para a modelagem ARIMA na análise de séries temporais sazonais determinísticas possibilitaram aplicar as teorias para construir um modelo confiável que visa prever informações com o intuito de controlar o consumo de energia elétrica. Com uma assertividade em torno de 89% conclui-se que o modelo é muito bom para prever a série de tempo estudada. Assim, a administração dessa instituição pode fazer uma boa gestão do recurso a partir desse método de previsão. Amparado neste estudo, há possibilidade de replicar tal controle que é deveras usual na rotina das pessoas e das organizações.

## Referências

- AMBER, K. P.; ASLAM, M. W.; MAHMOOD, A.; KOUSAR, A.; YOUNIS, M. Y.; AKBAR, B.; CHAUDHARY, G. Q.; KASHIF, S. Hussain Energy Consumption Forecasting for University Sector Buildings Energies. **MDPI**. Energies 2017, out. 2017, v. 10, n. 1579; doi:10.3390/en10101579. Disponível em: <www.mdpi.com/journal/energies>. Acessado em 21 ago. 2020.
- BOX, G. A. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. 1a. ed. San Francisco - CA, USA: Ed. Holden-Day (Revised edition, 1976), 1970.
- BOX, G. A. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis**. 4ª ed. Hoboken - NJ, USA: Wiley, 2008.
- CRYER, J. D.; CHAN, K. **Time Series Analysis**. 2ª ed. New York - NY, USA: Springer, 2008.
- CRYER, J. D.; CHAN, K. S. **Time series analysis with applications in R**. Springer Texts in Statistics. Springer. Second Edition. 2008. **EViews 10 User's Guide II**. 2ª ed. Irvine, CA: HIS Global Inc., 2017.
- KROLZIG, H. **Introduction to Time-Series Analysis**. Hilary Term, Vol. 1, p. 1-48, 2002.

LEE, Y. W.; TAT, K. G.; CHOY, Y. Y. Forecasting electricity consumption using times series model. **International Journal of Engineering and Technology**. 2018. Disponível em: <218-223. URL: 111.sciencepubco.com/index.php/IJET>. Acessado em 21 ago. 2020.

MADDALA, G. S. **Introduction to econometrics**. 2ª ed. New York – NY, USA: Macmillan Publishing Company, 1992.

MORAIS, I. A. C. de; STONA, F. S. G. **Econometria Aplicada no EViews®**. 1ª ed. Porto Alegre, RS: FEE, 2016.

MORETTIN, P. A.; TOLOI C. M. C. **Análise de Séries Temporais**. 2ª ed. São Paulo, SP: Blucher, 2006.

MORETTIN, P. A.; BUSSAB, W. O. **Estatística Básica**. 8ª ed. São Paulo, SP: Ed. Saraiva, 2013.

NOH, H. Y.; RAJAGOPAL, R. Data-driven forecasting algorithms for building energy consumption. **Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2013**. 86920T. 19 abr. 2013. Disponível em: <https://doi.org/10.1117/12.2009894>. Acesso em 21 ago. 2020.

OLIVEIRA, A. de; SILVEIRA, G. B. da; BRAGA, J. de M. Diversidade sazonal do consumo de energia elétrica no Brasil. **Pesquisa e Planejamento Econômico**. Vol. 30, n.2, p.211-258, 2000.

TEPEDINO, C.; GUARNACCIA, C.; ILIEV, S., POPOVA, S.; AND QUARTIERI, J.; Series analysis and forecast of the electricity consumption of local transportation. **Recent Advances in Energy, Environmental and Financial Planning**. ISBN: 978-960-474-400-8. Nov. 2014. Disponível em: <https://www.researchgate.net/publication/273443424\_Time\_Series\_Analysis\_and\_Forecast\_of\_the\_Electricity\_Consumption\_of\_Local\_Transportation>. Acessado em 20 ago. 2020.

TUBINO, D. F. **Planejamento e Controle da Produção: teoria e prática**. 1ª ed. São Paulo, SP: Atlas, 2007.

XAVIER, J. M. N. **Análise e previsão de séries temporais com modelos ARIMA e análise espectral singular**. Dissertação (Mestrado) - Universidade Aberta, p. 102, disponível em: <http://hdl.handle.net/10400.2/5873>. Acesso em 24 mar. 2020., 2016.