

UTILIZAÇÃO DOS MODELOS DE SÉRIES TEMPO-RAIS NA PREVISÃO DO CONSUMO MENSAL DE ENERGIA ELÉTRICA DA REGIÃO NORTE DO BRASIL

Pablo Vinicius Tidre

Universidade Federal de Uberlândia - Faculdade de Engenharia Elétrica
pablotidre@hotmail.com

Nádia Giaretta Biase

Universidade Federal de Uberlândia - Faculdade de Matemática
nadia@famat.ufu.br

Maria Imaculada de Sousa Silva

Universidade Federal de Uberlândia - Faculdade de Matemática
maria@famat.ufu.br

RESUMO

A capacidade de prever o consumo de energia elétrica de uma região é uma ferramenta importante para que seja garantida a produção da demanda futura. Desse modo, o presente artigo teve por objetivos analisar o consumo de energia elétrica na região Norte do Brasil e obter, por meio de séries temporais, um modelo matemático capaz de prever esse consumo. Dentre os possíveis modelos, foram ajustados modelos SARIMA sem e com intervenções. A seleção do melhor modelo foi realizada por meio dos critérios AIC (Akaike information Criterion), BIC (Information Bayesianano Criterion) e EQMP (Erro Quadrático Médio de Previsão). O modelo escolhido foi o SARIMA(2, 1, 2)(0, 1, 1)₁₂ com intervenção, que apresentou valores de previsão relativamente precisos.

ABSTRACT

The ability to predict the energy consumption of a region is an important tool that is guaranteed to produce the future demand. Thus, this paper aimed to analyze the energy consumption in northern Brazil and obtain, by means of time series, a mathematical model able to predict that consumption. Among the possible models were fitted SARIMA models with and without interventions. The best model selection was performed using the criterion AIC (Akaike information Criterion), BIC (Bayesian Information Criterion) and EQMP (Mean Square Error of Prediction). The best model selection was the SARIMA(2, 1, 2)(0, 1, 1)₁₂ with the intervention, which showed relatively accurate forecast values.

Palavras-chave: Tendência, sazonalidade, modelo SARIMA, intervenção, previsão.

1 INTRODUÇÃO

A energia elétrica desempenha um papel importante e imprescindível na sociedade atual, pois contribui para o desenvolvimento das diferentes regiões brasileiras, propor-

cionando grande comodidade à população. Segundo Schmidt e Lima [11], nas últimas décadas, o consumo de energia elétrica cresceu significativamente, impulsionado principalmente pelo bom desempenho e expansão dos setores industrial, comercial e residencial de nosso país.

No Brasil, a maior quantidade de energia elétrica produzida é proveniente das usinas hidrelétricas, e apenas uma pequena parte da energia consumida é produzida por usinas termoeletricas, eólicas e nucleares. No entanto, o país atualmente enfrenta grandes problemas relacionados à energia, uma vez que as construções das usinas geradoras proporcionam enormes impactos sócio-ambientais, dos quais se pode destacar, as desapropriações rurais e as grandes áreas de alagamento com destruição da fauna e da flora pelas represas de usinas hidrelétricas. Os danos ambientais e prejuízos ao convívio humano tendem a ser ainda piores com a construção das usinas termoeletricas e nucleares.

Esses fatos têm causado grande preocupação por parte da comunidade científica, devido às consequências futuras que a humanidade esta sujeita. Além disso, existe também uma preocupação com o uso eficiente e com o abuso do desperdício de energia elétrica no país, pois à falta de informação por parte da maioria dos consumidores que não administram com cautela o seu consumo, utilizam equipamentos elétricos de maneira inconveniente. Uma das medidas tomadas para amenizar e alertar toda a população sobre esse problema são as campanhas publicitárias de informação e estímulo a conservação da energia elétrica.

Sendo assim, é importante utilizar procedimentos e métodos estatísticos como instrumentos de análise para compreender e enriquecer a investigação científica referente ao consumo de energia elétrica em nosso país, buscando descrever e identificar padrões de comportamento ao longo dos anos, bem como analisar as relações presentes nas observações. Além disso, na análise de dados históricos é interessante empregar ferramentas estatísticas adequadas que explorem as informações contidas nos dados e que permita apresentar relatórios alinhados aos objetivos que se deseja alcançar, fornecendo conclusões a respeito do passado, como também uma possível previsão dos valores futuros a partir das variáveis analisadas.

Neste contexto, o estudo do comportamento de uma variável ao longo do tempo por meio de uma série temporal se torna importante. Segundo Morettin e Toloi [9], uma série temporal é qualquer conjunto de observações ordenadas no tempo, na qual a sequência dos dados é fundamental, visto que as observações apresentam correlação uma com as outras.

Geralmente, uma série temporal é decomposta pelas componentes: tendência, sazonalidade e o erro aleatório. A tendência representa o aumento ou a diminuição gradual das observações ao longo de um período e a sazonalidade indica as possíveis flutuações ocorridas, por exemplo, em subperíodos mensais, trimestrais ou semestrais. O erro aleatório constitui as oscilações aleatórias irregulares, sendo usual supor que este erro ou resíduo seja uma variável independente e identicamente distribuída com média zero e variância constante, para se obter um ajuste adequado de um modelo de série temporal.

Além destas componentes, algumas séries podem apresentar uma outra componente chamada intervenção, a qual representa a mudança de nível ou inclinações ocorridas com os dados em um determinado instante do tempo, devido a algum motivo conhecido ou não, que pode afetar temporariamente ou permanentemente a série em estudo (Box e Jenkins [2]).

Moreira [8] comenta que os métodos que se aplicam séries temporais buscam identificar tendência e sazonalidade nas observações da demanda ao longo do tempo. Em séries temporais, as observações levantadas têm um espaçamento constante em dias, em semanas, em meses ou em anos, por exemplo, e um dos pressupostos desses métodos é que os valores projetados podem ser estimados com base nos valores passados.

Para Morettin e Toloi [9] existem diversos métodos e modelos para analisar séries temporais, e uma modelagem estatística bastante difundida com essa finalidade é a de Box e Jenkins [2]. De modo geral, os modelos de Box e Jenkins consistem no ajuste de mode-

los Auto-Regressivos Integrados de Médias Móveis, denominados de ARIMA (p,d,q), a uma série temporal.

Para que seja possível ajustar um modelo de Box e Jenkins é necessário que a série seja estacionária, isto é, que ela se desenvolva ao longo do tempo em torno de uma constante, livre de tendência e sazonalidade. No entanto, a maioria das séries encontradas na prática apresenta algum tipo de não-estacionaridade e um procedimento utilizado para tornar essas séries estacionárias é tomar uma ou duas diferenças sucessivas na série original.

É possível, que mesmo após utilizar o operador de diferenças, a série ainda apresente correlações significativas nos lags sazonais, isto é, múltiplos do período sazonal. Para tal, é preciso ajustar à série original um modelo ARIMA sazonal, denominado SARIMA (Morettin e Toloi [9]).

Após ajustar um modelo de Box e Jenkins adequado, pode-se ter o interesse em prever valores futuros a partir deste modelo, com a finalidade de obter informações para uma consequente tomada de decisão. Abdel-Aal e Al-Garni [1] utilizaram os modelos de Box e Jenkins para prever o consumo mensal de energia elétrica no leste da Arábia Saudita, e ressaltaram que esses modelos têm sido largamente utilizados para modelagem e previsão em diversas aplicações, tais como, na área médica, ambiental, financeira e de engenharia.

Além das aplicações nas áreas mencionadas anteriormente, Lim e McAleer [7] comentam que a literatura na área de previsão de demanda turística é ampla ao considerar os diferentes métodos de previsão de séries temporais. Os próprios autores utilizaram a metodologia de Box e Jenkins para modelar a demanda de turistas que chegaram à Austrália proveniente de três países da Ásia.

Para prever o consumo de água para três bairros distintos da cidade de Ponta Grossa (PR), Falkenberg [6] apresentou diferentes modelos de previsão de consumo a curto prazo utilizando diferentes técnicas, tais como redes neurais artificiais, regressão linear múltipla e modelos do tipo Box e Jenkins, e obteve resultados satisfatórios, mesmo com a limitação dos dados e com a ausência de informações meteorológicas, uma vez que estes fatores influenciam diretamente no consumo de água.

Yang e Huang [13] desenvolveu um modelo Fuzzy autoregressivo de média móvel com variáveis exógenas de entrada (FARMAX) para prever dados de horários de carga a curto prazo. Siqueira e Júnior [12] propôs uma metodologia para incorporar os efeitos do racionamento nas previsões da demanda por energia elétrica, estimando a elasticidade renda e consumo, a longo e curto prazos, para as classes de consumo residencial, comercial e industrial da região Nordeste e concluíram que os métodos empregados permitiram obter previsões precisas e podem ser utilizados para prever o consumo de energia de qualquer região geográfica.

Campos [3] realizou previsões a longo prazo para a série do consumo de energia elétrica em Minas Gerais. Para obter as previsões ele utilizou os diferentes modelos: Autoregressive Integrated Moving Average (ARIMA), Non linear Autoregressive Integrated Moving Average (NARIMA), Rede Neuro-Fuzzy (NRF) e o Rede Neural (RNA) e comparou-os usando o erro quadrático médio (MSE), o erro percentual médio (MPE) e o erro percentual absoluto. Com este estudo o autor verificou que todos os modelos analisados proporcionaram excelentes resultados, e concluiu que eles podem auxiliar no planejamento e tomadas de decisões no setor elétrico.

Castro e Montini [4] utilizaram o modelo ARX para prever o consumo residencial de energia elétrica no Brasil. Para modelar a função de demanda de energia elétrica eles consideraram um modelo multiplicativo, incluindo quatro variáveis explicativas: tarifa residencial de energia elétrica, rendimento médio real das pessoas ocupadas, índice de inflação de utilidades domésticas e consumo de energia. O modelo proposto pelos referidos autores teve uma ótima performance na previsão do consumo de energia residencial do País.

Desse modo, o presente trabalho teve por objetivo ajustar modelos que melhor representem a série de consumo de energia elétrica da região Norte do Brasil, buscando identificar seus componentes e obter modelos de previsão para o consumo mensal de energia.

2 METODOLOGIA

Os dados avaliados referem-se ao consumo mensal de energia elétrica da região Norte do Brasil, correspondente ao período de janeiro de 1979 a dezembro de 2010 obtidos por meio do banco de dados do Instituto de Pesquisa Econômica Aplicada (IPEA), disponíveis na internet na página <<http://www.ipeadata.gov.br>>, totalizando 384 observações.

A princípio, a série foi analisada graficamente para averiguar a necessidade de uma transformação que estabilizasse a variância da série. Em séries econômicas e financeiras, segundo Morettin e Toloí [9], é comum ocorrer um acréscimo da variância à medida que o tempo passa, e neste caso, os referidos autores recomendam aplicar uma transformação logarítmica.

Para investigar a presença de tendência e periodicidades nos dados, analisou-se graficamente a série original e a função de autocorrelação, e em seguida, aplicaram-se os testes de Cox-Stuart e o de Fisher para confirmar a existência destas componentes.

Para realizar o teste de Cox-Stuart as observações foram comparadas, duas a duas, pelos seguintes pares: $(Z_1, Z_{1+c}), (Z_2, Z_{2+c}), \dots, (Z_{N-c}, Z_N)$, sendo c a razão entre o número total de observações e 2, isto é, $c = \frac{N}{2}$, uma vez que N era par. Para cada comparação, (Z_i, Z_{i+c}) , foi associado o sinal “+” se $Z_i < Z_{i+c}$, o sinal “-” se $Z_i > Z_{i+c}$ e os empates foram eliminados. Definiu-se n como sendo o número de comparações em que $Z_i \neq Z_{i+c}$, ou seja, o número total de comparações que gerou sinais positivos e negativos. As hipóteses testadas foram:

$$H_0 : P(Z_i < Z_{i+c}) = P(Z_i > Z_{i+c}), \forall_i : \text{não existe tendência};$$

$$H_1 : P(Z_i < Z_{i+c}) \neq P(Z_i > Z_{i+c}), \forall_i : \text{existe tendência}.$$

Admitindo T_2 como sendo o número de pares com sinal positivo, a hipótese H_0 é rejeitada nas situações que $T_2 \geq n - t$, em que t é obtido por meio da aproximação da distribuição normal da distribuição binomial com média np e variância $np(1-p)$ sempre que $n > 20$, sendo $p = 0,5$, considerando um nível de significância α .

A comprovação da sazonalidade foi verificada pelo teste de Fisher e foram testadas as seguintes hipóteses:

$$H_0 : \text{Não existe sazonalidade};$$

$$H_1 : \text{Existe sazonalidade}.$$

A estatística do teste é dada por:

$$g = \frac{\max_j I_j^{(N)}}{\sum_{j=1}^{\lfloor \frac{N}{2} \rfloor} I_j^{(N)}}$$

sendo I o valor do periodograma no período j e N o número de observações da série. A distribuição exata de g , é dada por $z_\alpha = 1 - (\frac{\alpha}{2})^{\frac{1}{c-1}}$ sendo $c = \frac{N}{2}$ e α o nível de significância. Se $g > z$, a hipótese H_0 é rejeitada e a série apresenta periodicidade no período j .

Após identificar as componentes da série, o operador diferença foi utilizado com a finalidade de torná-la estacionária. Modelos de Box e Jenkins, com e sem intervenção, foram ajustados e a adequabilidade de cada modelo foi testada por meio do teste de Box-Pierce, de acordo com a descrição apresentada por Morettin e Toloí [9]. Posteriormente, para selecionar o melhor modelo dentre os modelos ajustados para a série em estudo, foram utilizados os seguintes critérios: Critério de Informação de Akaike (AIC), Critério de Informação Bayesiano (BIC) e o Erro Quadrático Médio de Previsão (EQMP)(Priestley [10]).

O Critério de Informação de Akaike (AIC) é obtido pela seguinte expressão:

$$A(k, l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2(k+l)}{N},$$

em que: $\hat{\sigma}_{k,l}^2$ é a estimativa da variância residual, k e l representam as ordens dos parâmetros do modelo, $0 \leq k \leq p$ e $0 \leq l \leq p$ e N o número de observações da série.

A estatística do Critério de Informação Bayesiano (BIC) é dada por:

$$BIC(k, l) = \ln \hat{\sigma}_{k,l}^2 + (k + l) \frac{\ln N}{N},$$

sendo $\hat{\sigma}_{k,l}^2$ a estimativa de máxima verossimilhança da variância residual.

O Erro Quadrático Médio de Previsão (EQMP) baseia-se na média dos quadrados das diferenças entre valores observados e valores preditos, com origem em t , e calculado por meio da fórmula:

$$EQMP = \frac{1}{N} \sum_{h=1}^n [Z_{t+h} - \hat{Z}_t(h)]^2,$$

em que: Z_{t+h} é o valor real, h é o número de previsões e $\hat{Z}_t(h)$ é o valor predito.

O modelo escolhido foi aquele que apresentou o menor valor para esses critérios, e a partir deste modelo, foi realizada a previsão do consumo mensal de energia elétrica da região Norte do Brasil.

Para avaliar o consumo de energia elétrica da região Norte por meio de modelos de séries temporais foi utilizado o programa R.2.15 (R. Development Core Team [5], 2012).

3 RESULTADOS E DISCUSSÃO

Na Figura 1 é apresentado o gráfico da série original do consumo de energia elétrica (em GWh) da região Norte do Brasil. Pode-se observar que, ao longo dos anos, o consumo de energia na região Norte vem crescendo consideravelmente, havendo algumas pequenas oscilações durante o período em estudo.




FIGURA 1: Série original do consumo de energia elétrica na região Norte no período de janeiro de 1979 à dezembro de 2009.

Para verificar se a variabilidade dos dados aumentava com o passar do tempo, plotou-se a média em relação à amplitude dos dados, conforme pode ser visualizado na Figura 2 (a). Por meio desta figura, verificou-se que a variância dos dados é instável, portanto, uma transformação logarítmica foi aplicada para estabilizar a variância, ilustrada na Figura 2 (b). Desta forma, foi considerada a série transformada $Y = \ln(\text{consumo de energia})$.

Pela análise visual da série transformada do consumo de energia elétrica da região Norte, ilustrada na Figura 3, existem indícios de que a série apresenta uma tendência crescente e uma sazonalidade, que aparentemente, não se manifesta de forma tão expressiva.

Pelo teste de Cox-Stuart foram comparados $c = 186$ pares, que resultaram em 186 sinais positivos, não havendo, portanto, nenhuma comparação que resultasse em sinais negativos ou empates. Neste caso, tanto T_2 que representa o número de sinais positivos, como n que denota o número de pares em que $Z_i \neq Z_{i+c}$ foram iguais a 186 e o valor de t , obtido da aproximação da distribuição normal da distribuição binomial com média 93 e variância 46,5, foi igual a 104,22. Como $T_2 > n - t$ a hipótese de nulidade, H_0 : Não existe tendência, foi rejeitada ao nível nominal de significância de 5%, chegando-se a conclusão de que a série em estudo apresenta tendência positiva.

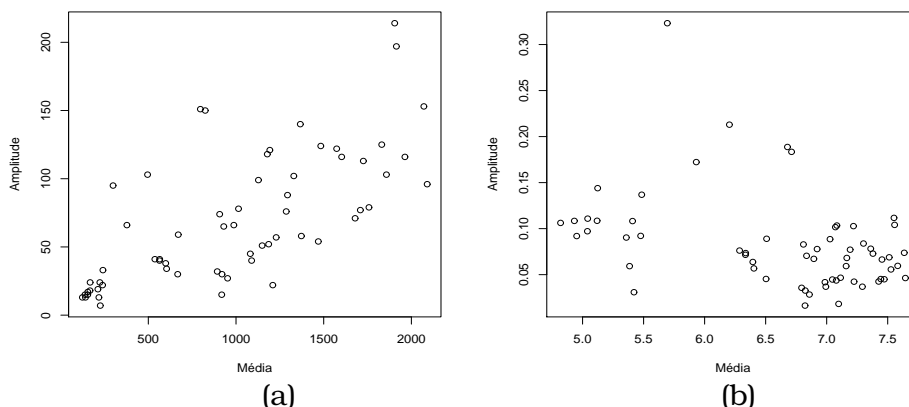


FIGURA 2: Gráfico da média em relação à amplitude da série original (a) e da série transformada (b) do consumo de energia elétrica região Norte.




FIGURA 3: Série transformada do consumo de energia elétrica na região Norte.

De acordo com o teste de Fisher, o valor da estatística g , $g = 0,0861$, é maior do que o valor de z , $z = 0,0197$, permitindo, assim, rejeitar a hipótese H_0 de que a série não existe sazonalidade e confirmando a existência da componente sazonalidade para períodos de 12 meses ao nível nominal de significância de 5%.

A tendência caracteriza um estágio não estacionário, e como o ajuste dos modelos pressupõe estacionariedade, a série foi diferenciada uma vez para eliminar esta componente, e aplicou uma diferença de 12, para eliminar a sazonalidade. O gráfico da série diferenciada pode ser visto na Figura 4. Observando ainda essa figura, é possível verificar alguns picos na série diferenciada, que podem representar possíveis intervenções.




FIGURA 4: Gráfico da série diferenciada do ln (consumo de energia elétrica) da região Norte.

Na Figura 5 são apresentadas as funções de autocorrelação e autocorrelação parcial da série diferenciada, que auxiliam na identificação dos modelos a serem ajustados. Observando as funções de autocorrelação e autocorrelação parcial, verifica-se que a série decai rapidamente para zero, o que significa que a tendência e a sazonalidade foram eliminadas, porém ainda existem correlações significativas nos lags sazonais, tanto da fac como da facp, indicando o ajuste de modelos do tipo SARIMA(p,d,q)(P,D,Q), representado pela seguinte expressão:

$$\phi(B)\Phi(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\Theta(B^s)a_t,$$

em que:

$\phi(B) = 1 - \phi_1(B^1) - \phi_2(B^2) - \dots - \phi_p(B^p)$ é o polinômio autorregressivo de ordem p;

$\Phi(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^s) - \dots - \Phi_P(B^P)$ é o polinômio autorregressivo sazonal de ordem P;

$\Delta^d = (1 - B^s)^d$ é o operador diferença e d indica o número de diferenças necessárias para retirar a tendência da série;

$\Delta_s^D = (1 - B^s)^D$ é o operador diferença sazonal e D indica o número de diferenças sazonais necessárias para retirar a sazonalidade da série;

$\theta(B) = 1 - \theta_1(B^1) - \theta_2(B^2) - \dots - \theta_q(B^q)$ é o polinômio médias móveis de ordem q;

$\Theta(B^s) = 1 - \Theta_1(B^s) - \Theta_2(B^s) - \dots - \Theta_Q(B^{Qs})$ é o polinômio médias móveis sazonal de ordem Q;

Z_t é a variável resposta do modelo;

a_t é o resíduo do modelo, que eventualmente, pode ser considerado como ruído branco. Desse modo, foram propostos os modelos:

- SARIMA(2, 1, 1)(0, 1, 1)₁₂;
- SARIMA(2, 1, 1)(0, 1, 1)₁₂ com intervenção nas observações 42 (junho de 1982) e 149 (maio de 1991);
- SARIMA(2, 1, 2)(0, 1, 1)₁₂;
- SARIMA(2, 1, 2)(0, 1, 1)₁₂ com as mesmas intervenções citadas anteriormente.

Todos estes modelos foram ajustados com sucesso, uma vez que as estimativas dos parâmetros e das intervenções foram todas significativas e os resíduos de cada modelo foram considerados estacionários.




FIGURA 5: Gráficos da função de autocorrelação (fac) e função de autocorrelação parcial (facp) da série diferenciada.

O efeito do aumento do consumo de energia elétrica na região Norte, refletido em junho de 1982 e maio de 1991, pode ser justificável pela instalação de um número considerável de indústrias de alta tecnologia, responsáveis pela produção de eletro-eletrônicos e também ligadas à atividade de exploração e processamento do minério de ferro, que envolve elevado consumo de energia elétrica devido aos grandes volumes de produção envolvidos.

Modelo	Graus de liberdade	Q_{40}	p-valor
SARIMA(2, 1, 2)(0, 1, 1) ₁₂	35	43,15	0,999
SARIMA(2, 1, 2)(0, 1, 1) ₁₂ *	31	40,77	0,999
SARIMA(2, 1, 1)(0, 1, 1) ₁₂	36	48,82	0,999
SARIMA(2, 1, 1)(0, 1, 1) ₁₂ *	32	40,22	0,999

* Modelo com intervenção

TABELA 1: Estatística do teste Box-Pierce para os modelos ajustados.

Na Tabela 1 são apresentadas as estatísticas para o teste Box-Pierce dos modelos ajustados, que permite verificar se o resíduo do modelo é independente e identicamente distribuído. De acordo com essa tabela, pode-se observar que para os quatros modelos o p-valor é superior ao nível de significância de 5%. Portanto, para cada modelo o teste foi não significativo, o que implica que os resíduos podem ser considerados ruído branco, e consequentemente, os dados se ajustam adequadamente a estes modelos.

Dentre os modelos ajustados, a escolha do melhor modelo de previsão foi feita com base nos critérios de AIC, BIC e o EQMP. Na Tabela 2 são apresentados os valores obtidos desses critérios para cada modelo, e de acordo com esses resultados, o SARIMA(2, 1, 2)(0, 1, 1)₁₂ com intervenção na observação 42, referente a junho de 1982 e na observação 149, referente a maio de 1991, foi o modelo escolhido para representar a série do consumo de energia elétrica na região Norte, uma vez que apresentou o menor valor para os três critérios adotados.

Modelo	AIC	BIC	EQMP
SARIMA(2, 1, 2)(0, 1, 1) ₁₂	-2461,87	-6,8143	2105,63
SARIMA(2, 1, 2)(0, 1, 1) ₁₂ *	-2483,15	-6,8195	2023,42
SARIMA(2, 1, 1)(0, 1, 1) ₁₂	-2455,12	-6,8122	2312,75
SARIMA(2, 1, 1)(0, 1, 1) ₁₂ *	-2474,16	-6,8164	2229,32

* Modelo com intervenção

TABELA 2: Critérios de informação para escolha do melhor modelo ajustado.

A Tabela 3 apresenta o consumo real e o previsto para o ano de 2010, como também

o erro de previsão para o modelo SARIMA(2, 1, 2)(0, 1, 1)₁₂ com intervenção. De modo geral, pode-se observar que houve uma aproximação entre os valores preditos e os reais, porém, na maioria dos casos, houve uma tendência em superestimar os valores reais.

Modelo	Meses	Consumo real(GWh)	Consumo previsto(GWh)	Erro de previsão
SARIMA(2, 1, 2)(0, 1, 1) ₁₂ *	Jan	2050,00	2074,00	-24,88
	Fev	1953,00	1962,00	-9,89
	Mar	2102,00	2031,00	70,14
	Abr	2137,00	2046,00	90,91
	Mai	2128,00	2094,00	33,98
	Jun	2152,00	2128,00	23,82
	Jul	2146,00	2136,00	9,13
	Ago	2179,00	2192,00	-13,55
	Set	2279,00	2221,00	57,23
	Out	2316,00	2246,00	69,75
	Nov	2253,00	2237,00	15,41
	Dez	2222,00	2225,00	-3,60

* Modelo com intervenção

TABELA 3: Previsão do consumo de energia elétrica para a região Norte para o ano de 2010.

Assim, a série do consumo de energia elétrica da região Norte do Brasil, para fins de previsão pode ser descrita pelo modelo SARIMA(2, 1, 2)(0, 1, 1)₁₂ com intervenção e representada pela seguinte expressão:

$$Z_t = \frac{-0,0567}{1 + 0,5108B} x_{1,t} + \frac{0,0962}{1 - 0,9730} x_{2,t} + \frac{(1 + 0,4282 + 0,8590B^2)(1 - 0,7082B^{12})}{(1 - B)(1 - B^{12})(1 + 0,5616B + 0,8359B^2)} a_t$$

em que as variáveis dummy são:

$$x_{1,t} = \begin{cases} 0 & \text{se } t \neq 42 \\ 1 & \text{se } t = 42 \end{cases} \text{ e } x_{2,t} = \begin{cases} 0 & \text{se } t \neq 149 \\ 1 & \text{se } t = 149 \end{cases}$$

4 CONCLUSÕES

Os modelos SARIMA foram ajustados adequadamente e apresentaram previsões relativamente próximas as observadas, detectando a sazonalidade, a tendência e as intervenções presentes na série. Entre os modelos ajustados com e sem intervenção, verificou-se que o modelo SARIMA(2, 1, 2)(0, 1, 1)₁₂ com intervenção foi o que apresentou melhor resultados para prever o consumo mensal de energia elétrica na região Norte do Brasil.

AGRADECIMENTOS

Os autores agradecem a PROGRAD-DIREN pelo auxílio financeiro recebido no desenvolvimento desse trabalho e na concessão da bolsa de iniciação científica.

REFERÊNCIAS

- [1] R. E. Abdel-Aal e Z. A-Igarni: *Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate time-series analysis*. Energy, 22:1059–1069, 1997.

- [2] G. P. Box e G. M. Jenkins: *Time series analysis, forecasting and control*. San Francisco: Holden-Day, 1976.
- [3] R. J. Campos: *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*. Tese de Mestrado, Universidade Federal de Minas Gerais, 2008.
- [4] J. B. Castro e A. A. Montini: *Previsão do consumo residencial de energia elétrica no Brasil: aplicação do modelo ARX*. *Future Studies Research Journal*, 2:03–16, 2010.
- [5] R. Development Core Team: *R: A language and environment for statistical computing*, 2012. Disponível em: <http://www.r-project.org>. Acesso em: 05 jun. 2012.
- [6] A. V. Falkenberg: *Previsão de Consumo Urbano de água a Curto Prazo*. Tese de Mestrado, Universidade Federal do Paraná, 2005.
- [7] C. Lim e M. McAleer: *Time series forecasts of international travel demand for Australia*. *Tourism Management*, 23:389–396, 2002.
- [8] D. A. Moreira: *Administração da produção e operações*. São Paulo: Pioneira, 1996.
- [9] P. A. Morretin e C. M. C. Toloi: *Análise de séries temporais*. São Paulo: Edgard Blucher, 2006.
- [10] M. B. Priestley: *Spectral analysis and time series*. New York : Academic Press, 1989.
- [11] C. A. J. Schmidt e M. A. M. Lima: *A demanda por energia elétrica no Brasil*. *Revista Brasileira de Economia*, 58:67–98, 2004.
- [12] M. L. Siqueira, H. H. C. Junior e I. Castela: *A demanda por energia elétrica no Nordeste brasileiro após o racionamento de 2001-2002: previsões de longo prazo*. *Pesquisa e Planejamento Econômico*, 36:137–178, 2006.
- [13] H. T. Yang e C. M. Huang: *A new short-term load forecasting approach using self-organizing fuzzy armax models*. *IEEE Transactions on Power Systems*, 13:217–225, 1998.