

ANÁLISE DE PREVISÕES PARA O CONSUMO DE ENERGIA ELÉTRICA NO NORDESTE DO BRASIL

Fábio P. Lima¹, Raphaela L. B. de Araújo¹, Jeniffer J. D. Sanchez², Raquel C. da Silva³

¹ Universidade Federal de Pernambuco – Departamento de Estatística

² Universidade de São Paulo – Departamento de Estatística

³ Universidade Regional do Cariri – Departamento de Matemática

RESUMO

A teoria de séries temporais é uma parte importante da estatística e econometria, tendo aplicações em diversas áreas como: finanças, meteorologia, ciências sociais e energia. De forma geral, uma série temporal é uma coleção de observações sobre algum fenômeno observadas em diferentes instantes do tempo (dias, meses, semestre, etc.). O objetivo principal do estudo de séries temporais é realizar previsões sobre o comportamento futuro, o que nos motiva a tomada de decisões. Neste trabalho é feita uma análise do consumo de energia elétrica no Nordeste do Brasil com dados que abrangem de janeiro de 1990 até setembro de 2013, levando em consideração o período de racionamento elétrico que atingiu a região, com o objetivo de determinar uma metodologia de previsão adequada para os próximos anos. Para tanto, são considerados os algoritmos de Holt-Winters em sua forma aditiva, multiplicativa e com atenuação de tendência, além da classe de modelos SARIMA e SARIMAX.

Palavras-chave: Consumo de energia. Nordeste. Séries temporais.

1. INTRODUÇÃO

O objetivo desse trabalho é modelar e fazer previsões sobre o consumo de energia elétrica em GWh (Gigawatt-hora) no Nordeste do Brasil e a partir daí analisar qual metodologia de previsão apresenta o melhor desempenho, possibilitando assim uma melhor previsão de consumo para os próximos anos. Para tanto, foram utilizados dados do site <http://www.ipeadata.gov.br> sobre o consumo de energia elétrica na região no período de janeiro de 1990 até setembro de 2013. O estudo é realizado usando alisamento exponencial (Holt-Winters aditivo, Holt-Winters multiplicativo e atenuação de tendência, ver [2]) e a

modelagem de Box-Jenkins, na qual foram utilizados o critério de informação de Akaike (AIC), o critério de informação de Akaike corrigido (AICC) e o critério de informação Bayesiano (BIC) [1].

2. METODOLOGIA

Os dados utilizados representam o consumo de energia elétrica, em GWh, na região Nordeste do Brasil de janeiro de 1990 até setembro de 2013, fornecendo assim $T = 285$ observações. O consumo médio de energia no período selecionado foi de 4:272 GWh, com pico de consumo em abril de 2013 e mínimo em junho de 1990.

Inicialmente, foi feita uma análise descritiva da série gerada a partir dos dados, que denominamos de *energ*. A Figura 1 mostra as observações da série ao longo tempo. Por sua vez, na Figura 2 (esquerda), temos o correlograma da série, que cai lentamente indicando não estacionariedade. Tal indicação foi reforçada pelo teste de Dickey-Fuller aumentado [4] e pelo gráfico da primeira diferença da série na Figura 2 (direita), indicando assim que a série é integrada de ordem 1.




Figura 1: Gráfico da série




Figura 2: Correlograma (esquerda) e Gráfico da primeira diferença da série (direita).

Para a realização das previsões criamos três novas séries *energ.1*, *energ.3* e *energ.6*. Com a série *energ.n* sendo obtida retirando as n últimas observações da série original. Nosso objetivo é prever o consumo de energia elétrica na região no mês de setembro, considerando previsões 1, 3 e 6 passos à frente, analisando qual metodologia de previsão tem o melhor desempenho.

Para tanto, seja n o número de observações retiradas da série e $k = T - n$. Vale lembrar que se $\hat{y}_i$ é uma previsão de y_i , o erro de previsão é dado por $e_i = y_i - \hat{y}_i$.

Foram consideradas para avaliar a capacidade preditiva dos métodos escolhidos as seguintes medidas:

1. Erro quadrático médio:


$$EQM = \frac{1}{n} \sum_{i=k+1}^T e_i^2;$$

2. Erro relativo:

$$ER = \frac{100 \times (y_i - \hat{y}_i)}{y_i};$$

3. Erro total:

$$ET = \sum_{i=k+1}^T e_i.$$



Para a modelagem dos dados, foram utilizadas a classe de algoritmos de alisamento exponencial e de modelos SARIMA e SARIMAX [2].

3. RESULTADOS E DISCUSSÃO

A Tabela 1 apresenta os resultados obtidos a partir da utilização dos algoritmos de Holt-Winters em sua forma aditiva (HWA) e sua forma multiplicativa (HWM), além dos obtidos utilizando atenuação de tendência (HT) no que se refere à previsão um passo à frente. Aqui, o algoritmo com atenuação de tendência foi o que demonstrou melhor capacidade preditiva, apresentando o valor mínimo para os três erros adotados.

No que se refere à previsão 3 passos à frente, tivemos um melhor desempenho do algoritmo de Holt-Winters aditivo, levando em conta o EQM e o ET. Porém, sua versão multiplicativa foi a que apresentou menor erro relativo. Por sua vez, para a série *energ.6*, o algoritmo HWM apresenta melhor capacidade preditiva, levando em conta o erro relativo e EQM.

Em seguida, foram realizadas previsões a partir da classe de modelos SARIMA. Para a determinação do melhor modelo foram utilizados os critérios de informação AIC, AICC e BIC. Para os critérios AIC e AICC foi escolhido o modelo $SARIMA(2,1,1) \times (2,0,0)$. Por sua vez, o $SARIMA(0; 1; 0) \times (2; 0; 0)$ foi o modelo escolhido ao se utilizar o critério BIC. No entanto, por questão de adequação à dinâmica dos dados, decidimos seguir com o primeiro modelo.

A Tabela 2 mostra que o modelo $SARIMA(0; 1; 0) \times (2; 0; 0)$ se mostrou eficiente nas previsões 1 e 3 passos à frente, apresentando erros relativo de aproximadamente 0.55% e 0.29%, respectivamente. Já na previsão 6 passos à frente, o modelo apresentou erro relativo de 2.56%, além de apresentar EQM e ET (em módulo) superiores aos dos algoritmos de alisamento exponencial.

Tabela 1: Previsões para set/2013 via algoritmos de alisamento exponencial

Previsão 1 passo à frente			
<i>energ.1</i>	HWA	HWM	HT
Previsão	6,603	6,621	6,596
Erro relativo (%)	0,916	1,198	0,813
EQM	0,004	0,006	0,003
ET	-0,06	-0,078	-0,053
Tipo de previsão	Superprevisão	Superprevisão	Superprevisão
Previsão 3 passos à frente			
<i>energ.3</i>	HWA	HWM	HT
Previsão	6,578	6,563	6,494
Erro relativo (%)	0,532	0,309	0,747
EQM	0,002	0,005	0,009
ET	0,055	0,14	0,264
Tipo de previsão	Superprevisão	Superprevisão	Subprevisão
Previsão 6 passos à frente			
<i>energ.6</i>	HWA	HWM	HT
Previsão	6,691	6,584	6,658
Erro relativo (%)	2,27	0,622	1,752
EQM	0,018	0,016	0,016
ET	-0,187	0,429	-0,186
Tipo de previsão	Superprevisão	Superprevisão	Superprevisão

Tabela 2: Previsão h passos à frente para setembro de 2013

SARIMA (2,1,1) x (2,0,0)	h=1	h=3	h=6
previsão	6.579	6.562	6.710
erro relativo (%)	0.545	0.289	2.558
EQM	0.001	0.002	0.021
ET	-0.036	0.063	-0.433
tipo de previsão	superprevisão	superprevisão	superprevisão

Para dar continuidade a modelagem dos dados foi considerado o período de racionamento elétrico que atingiu as regiões Sudeste, Centro-Oeste, Norte e Nordeste do país. Para tanto, foram criadas variáveis *dummies*, uma para cada série, que admitiam valor zero (representando atipicidade) no período de racionamento, junho de 2001 a fevereiro de 2002, e um nos demais períodos. Foi realizado então um novo ajuste, dessa vez incluindo tal variável como regressor no modelo selecionado via critérios de informação. Foi considerada então a adequação do modelo SARIMAX obtido à dinâmica dos dados, confirmada pela análise dos resíduos do modelo e p-valores do teste de Ljung-Box [3].

A Tabela 3 apresenta os resultados obtidos para o modelo SARIMAX (2,1,1) x (2,0,0). Considerando a série *energ.1*, tal modelo mostrou ter a melhor capacidade preditiva, apresentando os menores valores para os três erros adotados. Já para a previsão 3 passos à frente, o modelo ainda apresenta os menores EQM e ET, mas apresenta erro relativo maior a

quase todos os outros métodos testados. Por sua vez, na previsão 6 passos à frente, tal modelo mostra-se inferior aos demais com relação ao EQM e ET.

Tabela 3: Previsão h passos à frente para setembro de 2013

SARIMA (2,1,1) x (2,0,0)	h=1	h=3	h=6
previsão	6.575	6.583	6.725
erro relativo (%)	0.482	0.610	2.782
EQM	0.001	0.001	0.024
ET	-0.032	0.033	-0.526
tipo de previsão	superprevisão	superprevisão	superprevisão

Foram consideradas ainda previsões obtidas da média entre as combinações possíveis entre as três melhores previsões, com objetivo de determinar previsões com menor ER. No entanto, resolvemos descartar as mesmas, já que, com exceção de uma, todas as previsões obtidas durante este trabalho apresentaram superprevisão. Note que, nesse caso, a combinação de previsões apresentaria erro relativo maior ou igual ao da previsão de menor ER da combinação.

A Tabela 4 traz as previsões de consumo de energia elétrica no Nordeste do Brasil para o período de outubro de 2013 até março de 2014. Para as previsões foram considerados os algoritmos de Holt Winters aditivo, Holt Winters multiplicativo e com atenuação de tendência, além dos modelos SARIMA (2,1,1) x (2,0,0) e SARIMAX (2,1,1) x (2,0,0).

Tabela 4: Previsão de consumo de energia elétrica no Nordeste

mês/ano	HWA	HWM	HT	SARIMA	SARIMAX
out/2013	6.733	6.806	6.676	6.643	6.662
nov/2013	6.715	6.829	6.667	6.613	6.621
dez/2013	6.761	6.911	6.675	6.668	6.679
jan/2014	6.744	6.920	6.696	6.751	6.767
fev/2014	6.521	6.631	6.484	6.630	6.638
mar/2014	6.795	6.920	6.643	6.798	6.813



4. CONSIDERAÇÕES FINAIS

O objetivo do trabalho era avaliar o desempenho de diversas metodologias de previsões na previsão do consumo de energia elétrica na região Nordeste do Brasil. Os resultados obtidos mostram que o modelo SARIMAX apresenta melhor capacidade preditiva que os demais quando a previsão é feita poucos passos (1 e 3) à frente e que a medida que vamos aumentando os passos (aqui consideramos até 6) seu desempenho vai se igualando aos dos algoritmos de alisamento exponencial.

5. REFERÊNCIAS

- [1] Akaike, Hirotugu. "A new look at the statistical model identification." *Automatic Control, IEEE Transactions on* 19.6 (1974): 716-723.
- [2] Brockwell, Peter J., and Richard A. Davis. *Introduction to time series and forecasting*. Springer Science & Business Media, 2006.
- [3] Ljung, Greta M., and George EP Box. "On a measure of lack of fit in time series models." *Biometrika* 65.2 (1978): 297-303.
- [4] Said, Said E., and David A. Dickey. "Testing for unit roots in autoregressive-moving average models of unknown order." *Biometrika* 71.3 (1984): 599-607.