

UM ESTUDO COMPARATIVO DE MODELOS DE PREVISÃO PARA A CARGA DE DEMANDA DE ENERGIA ELÉTRICA DO SUBSISTEMA SUDESTE/ CENTRO-OESTE DO BRASIL.

Felipe Leite Coelho da Silva

Universidade Federal Rural do Rio de Janeiro, UFRRJ.
Departamento de Matemática
Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio.
Departamento de Engenharia Elétrica
felipeleite@ufrrj.br

Reinaldo Castro Souza

Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio.
Departamento de Engenharia Elétrica
reinaldo@ele.puc-rio.br

Fernando Luiz Cyrino Oliveira

Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio.
Departamento de Engenharia Industrial
cyrino@puc-rio.br

Plutarcho Maravilha Lourenço

Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio.
Instituto de Energia, IEPUC.
plutarchoml@gmail.com

RESUMO

O comportamento do consumo de energia elétrica no Brasil vem sendo amplamente investigado ao longo dos últimos anos. Este interesse, em geral, é devido ao grande impacto financeiro e social que a distribuição da energia elétrica pode acarretar, chegando a causar imensos prejuízos. Neste contexto, modelos de previsão tornam-se ferramentas úteis para a tomada de decisões. O objetivo deste trabalho é comparar modelos de previsão aplicados aos dados de carga de demanda de energia elétrica mensal do subsistema sudeste/centro-oeste do Brasil. Assim, foram utilizados os modelos de previsão de Holt-Winters aditivo, o SARIMA, o método *Singular Spectrum Analysis* (SSA) e o modelo linear dinâmico. O desempenho dos modelos foi comparado usando diferentes métricas estatísticas. Os resultados indicam que o modelo linear dinâmico forneceu melhores previsões, portanto, superando os outros modelos no período considerado.

PALAVRAS CHAVE. Modelo linear dinâmico, previsão, carga de demanda.

Área Principal: EST - Estatística

ABSTRACT

The electricity consumption behavior in Brazil has been extensively investigated over the years because of financial and social impacts it may cause to both electric power utilities and society. In this context, forecasting models become an important tool for supporting decisions, as it helps the utility to control investments without worsening the quality of service. This paper focuses

on comparing forecasting models applied to the load demand in southeast and midwest of Brazil. The forecasting models of Holt-Winters additive, SARIMA, Singular Spectrum Analysis (SSA) method, and dynamic linear model were used. The models' performances were compared based on statistical metrics. The results indicate that dynamic linear model provided better forecasts, therefore out performing the other models in the time period considered.

KEYWORDS. Dynamic linear model. Forecasting. Load demand.

Main Area: EST - Statistics



1. Introdução

O comportamento do consumo de energia elétrica no Brasil tem sido amplamente investigado ao longo dos últimos anos, devido a importância que a energia elétrica tem tanto em termos econômicos e sociais para um país ou região. Possíveis erros no planejamento do setor elétrico e possíveis problemas de fornecimento de energia podem causar prejuízos imensos para o país. Assim, as projeções do consumo de energia elétrica de um país ou uma região são informações de grande relevância na tomada de decisão de órgãos e entidades que atuam no setor energético.

Neste contexto, uma grande variedade de modelos vêm sendo utilizados, tais como os modelos de regressão múltipla (Ramanathan et al., 1997; Taylor e Buizza, 2003), os modelos de Box e Jenkins e de redes neurais artificiais (Taylor e McSharry, 2007; Santana et al., 2012) e, os modelos de amortecimento exponencial com regressão sazonal (Taylor e McSharry, 2007). Fan e Hyndman (2012) utilizaram os modelos semi-paramétricos para prever a demanda de energia elétrica na Austrália. Rahman (2013) apresentou resultados satisfatórios para a previsão da demanda de energia elétrica do setor residencial no Irã utilizando um modelo linear dinâmico bayesiano comparado com modelos de regressão e de redes neurais artificiais. Uma vantagem da abordagem bayesiana é a capacidade de levar em conta a incerteza dos parâmetros do modelo (Congdon, 2001).

A Empresa de Pesquisa Energética (EPE, 2011) define a carga de demanda como o montante máximo de energia (potência) que é necessário injetar no subsistema em um curto intervalo de tempo, a partir de usinas localizadas dentro do subsistema ou por importação de energia. Assim, a carga de demanda é fundamental para o sistema elétrico, de forma que geração e transmissão de energia devem suprir necessidades extremas de consumo. A carga de demanda está associada ao nível da carga de energia (consumo mais perdas), ou seja, ao patamar de consumo. Araujo (2013) utilizou um modelo de regressão dinâmica para prever a carga de energia do Sistema Interligado Nacional (SIN). De acordo com EPE (2011), as previsões de demanda de eletricidade de longo e médio prazo no Brasil são realizadas utilizando as abordagens do tipo *bottom-up* e *top-down*, que agregam e desagregam previsões dos níveis hierárquicos, respectivamente. Em geral, propõe-se um método para prever carga de energia ou demanda de energia para, em seguida, prever a carga de demanda.

O objetivo deste trabalho é comparar diferentes modelos de previsão aplicados aos dados de carga de demanda de energia elétrica mensal do subsistema sudeste/centro-oeste do Brasil. Sendo assim, buscamos encontrar o modelo de previsão que melhor se ajuste aos dados e que apresente o melhor desempenho na previsão. Os dados de carga de demanda (MWh/h) de energia elétrica utilizados neste trabalho estão disponíveis no sítio eletrônico do Operador Nacional do Sistema Elétrico (ONS), para as regiões geográficas do Brasil em vários intervalos temporais.

Neste trabalho, a fim de prever carga de demanda de energia elétrica, propomos o ajuste de diferentes modelos de previsão utilizando ambas as abordagens clássica e bayesiana, e o método *Singular Spectrum Analysis* (SSA). Para a primeira abordagem, utilizamos o modelo Holt-Winters aditivo (Granger e Newbold, 1977; Winters, 1960) e o modelo SARIMA (Box et al., 1994) que são modelos de previsão de séries temporais bem estabelecidos na literatura. Em seguida, foi utilizado o método SSA (Golyandina et al., 2009) que não depende das suposições estatísticas relacionadas tanto com o sinal ou ruído durante a sua aplicação. Finalmente, propomos um modelo bayesiano linear dinâmico (West e Harrison, 1997) que permite estruturas temporais bastante flexíveis, tais como um passeio aleatório simples, crescimento linear ou sazonalidade, entre outras.

Os modelos clássicos têm sido amplamente empregados para a previsão de séries temporais ao longo dos anos, produzindo previsões pontuais satisfatórias para séries que apresentam um comportamento relativamente estável. No entanto, eles não se ajustam em situações de elevada instabilidade da série e, além disso, alguns também não são versáteis o suficiente para incorporar, tanto na análise como na previsão, todo o conjunto de informações (quantitativas ou qualitativas), disponível ao analista.

O método SSA e os modelos bayesianos passaram a ser empregados em previsão de séries

temporais mais recentemente, com o aparecimento de ferramentas computacionais mais eficientes. A abordagem bayesiana é amplamente conhecida e tem sido adotada na previsão da demanda de eletricidade (Ohtsuka et al., 2010). Ela se aplica a uma gama maior de séries temporais e permitem incorporar um conjunto de informações mais abrangentes do que os modelos clássicos, sendo assim mais versáteis. SSA é uma técnica não paramétrica que combina elementos de séries temporais, estatística multivariada, sistemas dinâmicos e processamento de sinais. Essa técnica visa a decomposição da série original em um número menor de componentes independentes e interpretáveis como a tendência, componentes de sazonalidade e ruído.

O trabalho está organizado da seguinte forma: na seção 2 apresentamos uma breve descrição teórica dos modelos e métodos de previsão. Em seguida, na seção 3, mostramos os resultados obtidos. Finalmente, na seção 4 são apresentadas as principais conclusões.

2. Metodologia

Neste trabalho, foram utilizados os dados de carga de demanda mensais de janeiro de 2000 até dezembro de 2014 do subsistema sudeste/centro-oeste do Brasil. Utilizamos os dados de 2000 a 2010 para ajustar os modelos, retirando os últimos 4 anos (2011 a 2014) da amostra a fim de avaliarmos os modelos quanto à qualidade na previsão. O período de tempo observado abrange o ano que em os reservatórios atingiram o nível muito baixo da história (2001) e a crise financeira mundial iniciada em 2008 com reflexos na economia em 2009.

Os modelos de Holt-Winters, SARIMA, SSA e linear dinâmico foram implementados levando em conta as suas características (de nível, tendência, ciclo, sazonalidade e ruído).

Seja Y_t a carga de demanda de energia no mês t , para $t = 1, \dots, T$, com T representando o total de meses da série. Abaixo descrevemos brevemente os quatro modelos propostos e comparados neste trabalho.

- (i) O método de Holt-Winters foi utilizado por se ajustar a uma grande variedade de séries temporais, conseguindo captar as suas características com eficiência. Existem dois modelos de Holt-Winters, o aditivo para séries homocedásticas e o multiplicativo para séries heterocedásticas. Os dois tipos foram modelados e os seus erros de previsão calculados, usando os dados observados. Analisando a soma dos quadrados dos erros, verificamos que o modelo sazonal aditivo é o mais adequado para série, isto é, para cada $t = 1, \dots, T$,

$$Y_t = a_1 + b_1 t + \gamma_t + \epsilon_t, \quad (1)$$

onde ϵ_t é o ruído e, a_1 , b_1 e γ_t são, respectivamente, os parâmetros de nível, tendência e sazonalidade.

- (ii) Os modelos de Box & Jenkins determinam o processo estocástico adequado para representar uma determinada série temporal através da passagem de um ruído branco por um filtro linear. O modelo utilizado foi o ARIMA sazonal multiplicativo (SARIMA), para incorporar a componente de sazonalidade que está presente nos dados.

A estrutura do modelo SARIMA de ordem $(p, d, q) \times (P, D, Q)_s$ é dado por

$$\phi(B)\Phi(B^s)\nabla^d\nabla_s^D Y_t = \theta(B)\Theta(B^s)a_t, \quad (2)$$

em que $\phi(B)$ é o operador auto-regressivo de ordem p ; $\theta(B)$ é o operador de médias móveis de ordem q ; $\Phi(B^s)$ é o operador auto-regressivo sazonal de ordem P ; $\Theta(B^s)$ é o operador de médias móveis sazonal de ordem Q ; ∇^d é o operador da diferença simples e; ∇_s^D é o operador da diferença sazonal; a_t é um ruído branco.

- (iii) O método SSA é uma técnica não paramétrica que consiste em dois estágios complementares, o de decomposição e o de reconstrução de uma série temporal. As suas principais características é a filtragem e a previsão. De acordo com Golyandina et al. (2009), a ideia básica

de SSA consiste primeiramente em obter a matriz de trajetória X para uma série temporal $Y_T = (y_1, y_2, \dots, y_T)$ de tamanho T . A matriz de trajetória X com a janela de comprimento L é definida por

$$X = [X_1, X_2, \dots, X_K] = (x_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} y_1 & y_2 & y_3 & \cdots & y_K \\ y_2 & y_3 & y_4 & \cdots & y_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & y_{L+2} & \cdots & y_T \end{bmatrix},$$

onde $K = T - L + 1$ e $L \leq \frac{T}{2}$. Em seguida, através da decomposição em valores singulares (SVD) de XX^T são obtidos L autovalores ($\lambda_1, \lambda_2, \dots, \lambda_L$) com seus respectivos autovetores normalizados (U_1, U_2, \dots, U_L). A SVD da matriz de trajetória pode ser escrita por

$$X = E_1 + E_2 + \cdots + E_d,$$

onde $E_i = \sqrt{\lambda_i} U_i V_i^T$, $i = 1, 2, \dots, d$, sendo d o número de autovalores não nulos de XX^T , e V_i são as componentes principais definidas por $V_i = X^T U_i / \sqrt{\lambda_i}$. E, finalmente deve-se agrupar as matrizes $\{E_i\}_{i=1}^d$ em r grupos disjuntos (G_1, G_2, \dots, G_r), com $1 \leq r \leq d$. Sendo assim, as componentes do SSA podem ser agrupadas pela tendência, sazonalidade e ruído.

- (iv) O modelo linear dinâmico bayesiano (West e Harrison, 1997) utilizado neste trabalho considera o crescimento linear e a sazonalidade:

$$\begin{aligned} Y_t &= \mu_t + \gamma_t + \epsilon_t, & \epsilon_t &\sim N(0, V_\epsilon), \\ \mu_t &= \mu_{t-1} + \beta_{t-1} + \delta_{\mu t}, & \delta_{\mu t} &\sim N(0, V_\mu), \\ \beta_t &= \beta_{t-1} + \delta_{\beta t}, & \delta_{\beta t} &\sim N(0, V_\beta), \\ \gamma_t &= -\sum_{i=1}^{11} \gamma_{t-i} + \delta_{\gamma t}, & \delta_{\gamma t} &\sim N(0, V_\gamma), \end{aligned} \quad (3)$$

em que μ_t é o nível em t , β_t é a inclinação em t , γ_t é o fator sazonal, V_ϵ é a variância observacional, V_μ , V_β e V_γ são as variâncias dos estados do sistema, e os erros ϵ_t , $\delta_{\mu t}$, $\delta_{\beta t}$ e $\delta_{\gamma t}$ são internamente e mutuamente independentes.

Para selecionar o modelo de previsão mais adequado foram utilizadas as seguintes métricas: erro quadrático médio (MSE), erro médio absoluto percentual (MAPE), erro médio absoluto (MAE), critério de informação de Akaike (AIC) e o coeficiente de desigualdade de Theil (U -Theil). Segue abaixo a definição das métricas adotadas neste trabalho, considerando-se que N é quantidade de valores previstos, \hat{y}_i é o valor previsto e y_i é o valor observado ambos para o instante i .

- (a) O erro quadrático médio é definido por

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2.$$

- (b) O erro médio absoluto é definido por

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|.$$

(c) O erro médio absoluto percentual (MAPE) é definido por

$$MAPE = 100 \times \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|.$$

As três medidas MSE e MAE MAPE são baseadas apenas no ajuste do modelo comparando-se os valores previstos médios com os observados.

(d) O Critério de Informação de Akaike (AIC) é uma medida da qualidade relativa de um modelo estatístico para um conjunto de dados e, é obtido por

$$AIC = 2k - 2\ln(L),$$

em que L é o valor maximizado da função de verossimilhança do modelo e k o número de parâmetros estimados no modelo.

(e) O coeficiente de desigualdade de Theil, U-Theil, fornece uma medida de quão bem a série temporal prevista se compara com a correspondente série temporal observada, sendo definido por

$$U = \sqrt{\frac{\sum_{i=2}^N (y_i - \hat{y}_i)^2}{\sum_{i=2}^N (y_i - y_{i-1})^2}}.$$

Para mais detalhes sobre essas medidas ver Petris et al. (2009). Todas as análises estatísticas foram realizadas através do software R 3.0.1 (*The R Foundation for Statistical Computing, Vienna, Austria; <http://www.r-project.org>*).

3. RESULTADOS E DISCUSSÃO

Nesta seção apresentaremos os resultados dos modelos de Holt-Winters aditivo, SARIMA, método SSA e o modelo linear dinâmico.

3.1. Modelo de Holt-Winters Aditivo

Na figura 1, mostramos o ajuste do modelo de Holt-Winters aditivo aos dados de carga de demanda de energia elétrica entre 2000 e 2010, assim como a previsão mensal para o horizonte quatro anos à frente.




Figura 1: Ajuste do modelo de Holt-Winters aditivo (linha cheia) aos dados de carga de demanda (“+”) no período de janeiro de 2000 a dezembro de 2010. Previsão mensal (linha tracejada azul) para o horizonte de quatro anos com seu respectivo intervalo de confiança de 95% (linha tracejada vermelha), sobrepostos aos valores observados neste período (círculos).

O valor obtido pela métrica U -Theil de 1,05, mostra que o modelo de Holt-Winters aditivo não é melhor do que a previsão ingênua.

3.2. Modelo SARIMA

Para identificar o modelo SARIMA mais adequado é necessário verificar o comportamento das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), figura 2. A figura 2(a) mostra que a função de autocorrelação decai lentamente para zero, indicando a não-estacionariedade da série. Portanto, a série precisa ser diferenciada com o objetivo de torná-la estacionária.

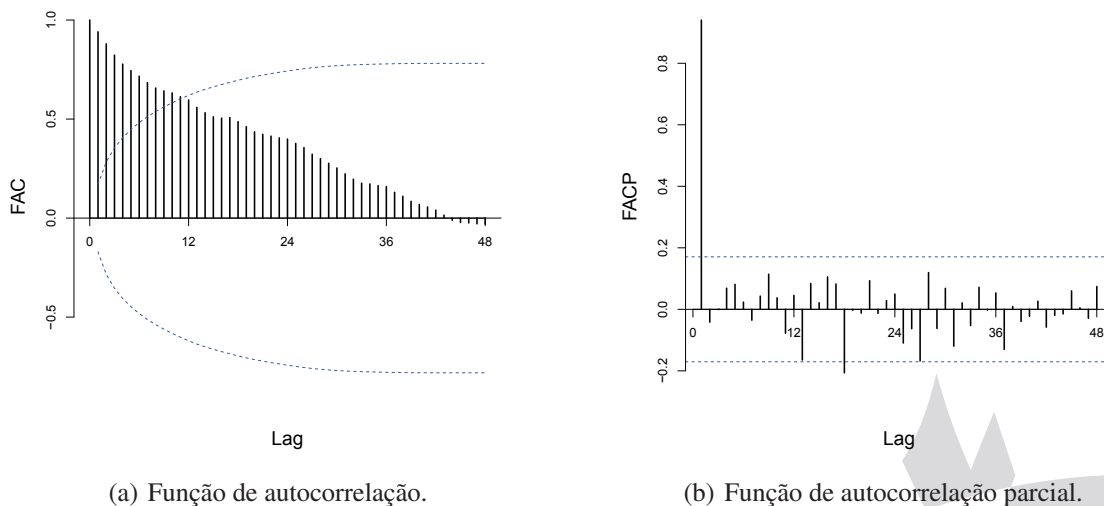


Figura 2: Funções de autocorrelação da série de carga de demanda, no período de 2000 a 2010.

Pela função de autocorrelação da série diferenciada (figura 3(a)), podemos observar um decaimento exponencial nos lags múltiplos de 12, o que indica a possibilidade de estacionariedade da série temporal. E, através dos testes de Dickey-Fuller (Dickey-Fuller = -4,9487, p-valor = 0,01) e Phillips-Perron ($Z_{\alpha} = -108,9628$, p-valor = 0,01) aceitamos a hipótese de estacionariedade da série diferenciada ao nível de significância superior a 1%. Além disso, a FAC aponta um corte significativo no lag 12 indicando a possibilidade de uma média móvel sazonal do modelo.

A FACP (figura 3(b)) aponta um corte atenuado no lag 8 e outro significativo no lag 12 indicando uma possível existência de uma ordem autoregressiva sazonal. Com base nas funções de autocorrelação, é possível que a estrutura do modelo seja um SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$. E, através do teste de sobrefixação para verificar a possibilidade da existência de um modelo de ordem mais elevada, foi encontrado o modelo SARIMA $(2, 1, 1) \times (1, 0, 1)_{12}$.

Portanto, os possíveis modelos escolhidos para o ajuste desta série temporal foram o SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$ e o SARIMA $(2, 1, 1) \times (1, 0, 1)_{12}$, com os respectivos valores de AIC 2194,14 e 2196,11. Baseados neste critério, o modelo mais adequado foi o SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$.

Na figura 4, apresentamos a função de autocorrelação dos resíduos do modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$ e o ajuste do modelo aos dados de carga de demanda e, a previsão mensal para o horizonte de quatro anos. Pela FAC (figura 4(a)), verificamos que o processo gerou um ruído branco, e pelo teste de Jarque-Bera o valor do p-valor é igual a 0,6306, o que nos leva a aceitar a hipótese de normalidade dos resíduos ao nível de significância de 5%.

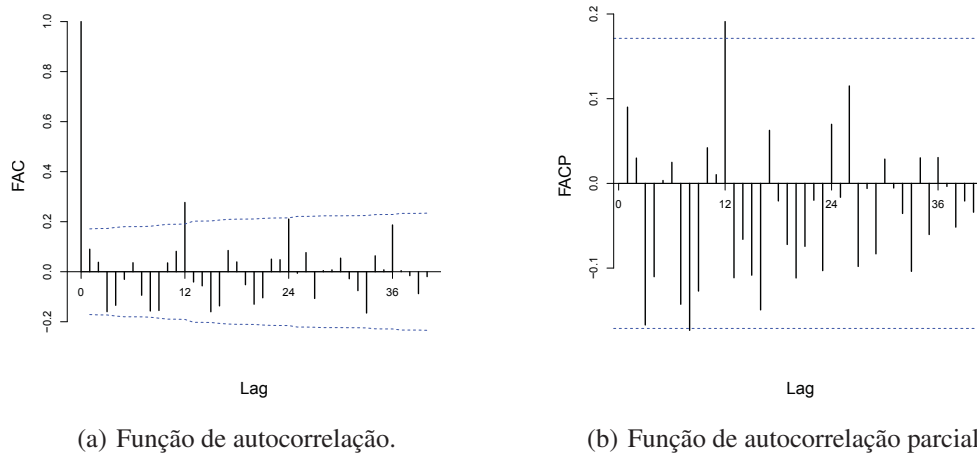


Figura 3: Funções de autocorrelação da série de carga de demanda diferenciada, no período de 2000 a 2010.

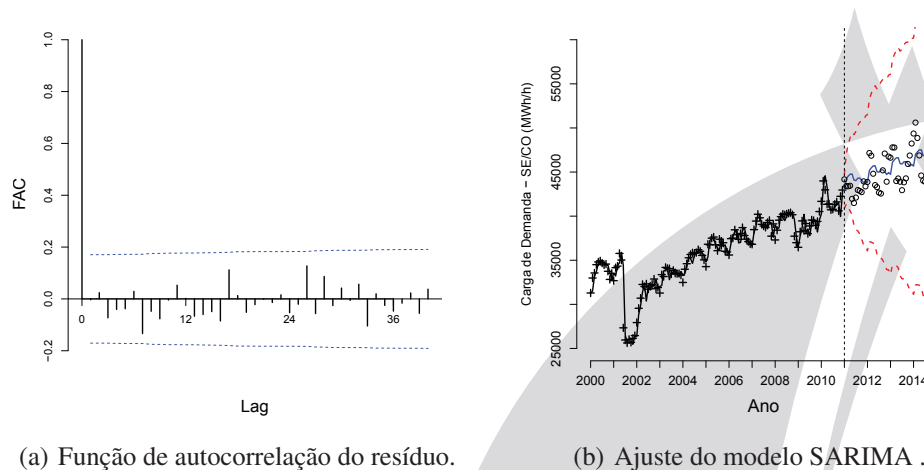



Figura 4: (a) Análise dos resíduos do modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$. (b) Ajuste do modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$ (linha cheia) aos dados de carga de demanda (“+”) no período de janeiro de 2000 a dezembro de 2010. Previsão (linha azul) para o horizonte de 4 anos com seu respectivo intervalo de confiança de 95% (linha tracejada vermelha), sobrepostos aos valores observados neste período (círculos).

3.3. Método SSA

Na aplicação do método SSA utilizamos uma janela de comprimento 36 para obter a matriz de trajetória (X), e que satisfaz as condições do método. Desta maneira, pela SVD de XX^T obtemos 36 autovalores. Na figura 5(a) podemos observar que ocorre uma variação não significativa a partir da componente 13 e que pode ser interpretado como o início do ruído segundo Hassani et al. (2009). A figura 5(b) mostra o ajuste e a previsão mensal da carga de demanda de energia elétrica para o horizonte de quatro anos à frente através do método SSA.



(a) Logaritmo dos autovalores.

(b) Ajuste pelo método SSA.

Figura 5: (a) Logaritmo dos autovalores. (b) Ajuste pelo método SSA (linha cheia) aos dados de carga de demanda (“+”) no período de janeiro de 2000 a dezembro de 2010. Previsão (linha tracejada azul) para o horizonte de 48 meses com seu respectivo intervalo de confiança de 95% (linha tracejada vermelha), sobrepostos aos valores observados neste período (círculos).

3.4. Modelo Linear Dinâmico

Consideramos as variâncias definidas nas equações em (3) conhecidas e grandes. Na figura 6, apresentamos o ajuste do modelo linear dinâmico aos dados de carga de demanda e a previsão mensal para os quatro anos à frente com seu respectivo intervalo de credibilidade de 95%.




Figura 6: Ajuste do modelo bayesiano de crescimento linear e sazonalidade (linha cheia) aos dados de carga de demanda (“+”) no período de janeiro de 2000 a dezembro de 2010. Previsão (linha tracejada azul) para o horizonte de 48 meses à frente com seu respectivo intervalo de credibilidade de 95% (linha tracejada vermelha), sobrepostos aos valores observados neste período (círculos).

3.5. Comparação entre os modelos Holt-Winters, SARIMA, linear dinâmico e o método SSA.

Pelos valores das métricas apresentadas na tabela 1, verificamos que o modelo linear dinâmico, com os menores valores em todas, ajustou-se melhor aos dados de carga de demanda de energia elétrica em comparação com o método SSA, o modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$ e o modelo de Holt-Winters.

Tabela 1: Comparação entre o método SSA, o modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$, o modelo Holt-Winters aditivo e o modelo linear dinâmico em relação ao ajuste dos modelos aos dados de carga de demanda, no período dos anos 2000 a 2010.

Modelo	MSE	MAE (%)	MAPE (%)	$U - Theil$
Holt-Winters aditivo	1306449	879,98	2,50	1,05
SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$	956648	625,69	1,78	0,89
Método SSA	204885	318,12	0,91	0,41
Modelo linear dinâmico	85698,64	210,60	0,59	0,27

Para comparar os modelos em relação aos seus desempenhos na previsão dos dados, utilizamos o erro quadrático médio e o erro médio absoluto percentual entre os valores previstos e os dados observados nesse período. Pelos resultados apresentados na tabela 2, novamente o modelo linear dinâmico demonstrou um melhor desempenho na previsão do que os modelos Holt-Winters, SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$ e o método SSA.

Tabela 2: Comparação das previsões utilizando o método SSA, o modelo SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$, o modelo Holt-Winters aditivo e o modelo linear dinâmico, no período de 2011 a 2014.

Modelo	MSE	MAPE (%)
Holt-Winters aditivo	6222786	4,92
SARIMA $(1, 1, 0) \times (1, 0, 1)_{12}$	4543766	4,01
Método SSA	9502356	5,36
Modelo linear dinâmico	4353932	3,98

4. CONCLUSÕES

Neste trabalho, utilizamos os modelos de Holt-Winters aditivo, SARIMA, linear dinâmico e o método SSA a fim de fazer previsão para a carga de demanda de energia elétrica do subsistema sudeste/centro-oeste do Brasil para o horizonte de 4 anos à frente, a partir dos dados do ONS de janeiro de 2000 até dezembro de 2010.

Pela métrica U -Theil, os modelos adotados nesse estudo mostraram superioridade em relação a previsão ingênua, exceto o modelo de Holt-Winters. Ressaltamos que esses modelos conseguiram capturar a estrutura complexa dos dados que envolvem as crises (picos nas séries) nos anos de 2001 e 2009. Com base nos valores das métricas MSE, MAE, MAPE, e U -Theil, verificamos que o modelo linear dinâmico apresentou o melhor ajuste aos dados e a melhor previsão. Essa performance do modelo linear dinâmico concorda com os resultados de Rahman (2013).

Na estimação do modelo linear dinâmico, supomos as variâncias das observações e dos parâmetros da evolução do sistema (nível, tendência e sazonalidade) conhecidas. Uma possível extensão seria estimar essas variâncias sob o paradigma bayesiano, supondo uma distribuição *a priori* para o vetor de parâmetros, representando um cenário mais realístico.

Referências

Araujo, T. G., Souza, R. C., *Ajuste das Séries de Carga de Energia Elétrica Influenciadas pelos Ofensores Calendário e Temperatura*, Dissertação de mestrado, DEE, PUC-Rio, 2013.

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C.**, *Time Series Analysis: Forecasting and Control*, 3^a ed., Prentice-Hall, 1994.
- Congdon, P.** *Bayesian Statistical Modeling*, Wiley, 2001.
- EPE-** Empresa de Pesquisa Energética, Séries Estudos de Energia, Nota Técnica DEA 03/11, *Projeção da demanda de energia elétrica para os próximos dez anos*, Rio de Janeiro, Fevereiro de 2011.
- Fan, S., Hyndman, R. J.** (2012), Short-term load forecasting based on a semi-parametric additive model, *IEEE Transactions on Power Systems*, 27, 134-141.
- Golyandina, N. , Nekrutkin, V. , Zhigljavsky, A.**, *Analysis of Time Series Structure: SSA and Related Techniques*, Chapman & Hall, CRC, 2001.
- Granger, C. W. J., Newbold, P.**, *Forecasting Economic Time Series*, Academic Press, New York, 1977.
- Hassani, H., Heravi, S., and Zhigljavsky, A.** (2009), Forecasting European Industrial Production with Singular Spectrum Analysis, *International Journal of Forecasting*, 25(1), 103-118.
- Ohtsuka, Y., Ogac, T., Kakamuc, K.** (2010), Forecasting electricity demand in Japan: a Bayesian spatial autoregressive ARMA approach, *Computational Statistics and Data Analysis*, 54, 2721-2735.
- Petris, G., Petrone, S., C., Patrizia**, *Dynamic Linear Models with R*, Springer, New York 2009.
- Rahman, M. A.** (2013), Dynamic Stochastic Model to Forecast Non-Stationary Electricity Demand, *International Journal of Engineering and Advanced Technology (IJEAT)*, 2, 2249-8958.
- Ramanathan, R., Engle, R., Granger, C.W.J., Vahid-Araghi, F. and Brace, C.** (1997), Short-run Forecasts of Electricity Loads and Peaks, *International Journal of Forecasting*, 13, 161-174.
- R Core Team** (2012), *R: A Language and Environment for Statistical Computing*, Vienna, Austria: R Foundation for Statistical Computing. ISBN 3-900051-07-0.
- Santana, A. L., G. B. Conde, L. P. Rego, C. A. Rocha, D. L. Cardoso, J. C. Costa, U. H. Bezerra, and C. R. Francs** (2012). Predict decision support system for load forecasting and inference: A new undertaking for brazilian power suppliers. *Electrical Power and Energy Systems*, 38, 33-45.
- Taylor, J.W., Buizza, R.** (2003), Using Weather Ensemble Predictions in Electricity Demand Forecasting, *International Journal of Forecasting*, 19, 57-70.
- Taylor, J.W., McSharry, P.E.** (2007), Short-term Load Forecasting Methods: an Evaluation Based on European Data, *IEEE Transactions on Power Systems*, 22, 2213-2219.
- West, M., Harrison, J.** *Bayesian Forecasting and Dynamic Models*, Springer, New York, 1997.
- Winters, P.** (1960), Forecasting sales by exponentially weighted moving average, *Management Science*, 6, 324-342.