

CONSUMO INDUSTRIAL DE ENERGIA ELÉTRICA: UM ESTUDO COMPARATIVO ENTRE MÉTODOS PREDITIVOS

INDUSTRIAL CONSUMPTION OF ELECTRICAL ENERGY: A COMPARATIVE STUDY BETWEEN PREDICTIVE METHODS

**Tiago Silveira Gontijo¹; Fabiano De Moro Rodrigues²; Alexandre de Cássio
Rodrigues³; Stela Alves da Silva⁴; Andressa Amaral de Azevedo⁵**

- 1 Mestre em Engenharia de Produção. UFMG, 2013, Docente do Centro Universitário Metodista Izabela Hendrix. Belo Horizonte, MG. tiago.gontijo@izabelahendrix.metodista.br
- 2 Graduado em Engenharia de Produção pelo Centro Universitário Metodista Izabela Hendrix, 2017. Belo Horizonte, MG. bdemoro@icloud.com
- 3 Mestre em Engenharia de Produção. UFMG, 2012, Docente do Centro Universitário Metodista Izabela Hendrix. Belo Horizonte, MG. alexandrerodrigues.engprod@gmail.com
- 4 Graduanda em Engenharia de Produção pelo Centro Universitário Metodista Izabela Hendrix, Belo Horizonte, MG. stelaalvessilva@gmail.com
- 5 Mestre em Engenharia de Produção. UFMG, 2007, Docente do Centro Universitário Metodista Izabela Hendrix. Belo Horizonte, MG. dressa.azevedo@gmail.com

Recebido em: 08/10/2017 - Aprovado em: 02/11/2017 - Disponibilizado em: 20/12/2017

RESUMO: O objetivo deste artigo é comparar o método mais adequado de previsão de demanda para o consumo de energia elétrica industrial no Brasil. Para isso, foi utilizada a série histórica de demanda energética no período de abril de 2007 a janeiro de 2017. Utilizou-se de análises comparativas entre quatro métodos de previsão de demanda: método de média móvel simples, média móvel ponderada, suavização exponencial e autoregressivo de média móvel (ARMA). Através de comparações, concluiu-se que, o método ARMA foi o mais adequado no ponto de vista da análise do erro médio. A respeito da análise do erro médio, considera-se o modelo eficaz, aquele que apresenta o menor valor. Diante do exposto, este estudo se torna uma alternativa que permite contribuir para trabalhos futuros.

PALAVRAS-CHAVE: Previsão de demanda, consumo de energia elétrica, erros de previsão.

ABSTRACT: The purpose of this article is to compare the most appropriate method of forecasting demand for the consumption of industrial electric energy in Brazil. For that, the historical series of energy demand was used from April 2007 to January 2017. Four methods of demand forecasting, simple moving average method, weighted moving average, exponential smoothing and autoregressive smoothing were used. Moving average (ARMA).

Through comparisons, it was concluded that the ARMA method was the most adequate from the point of view of mean error analysis. Regarding the analysis of the average error, it is considered the effective model, the one with the lowest value. In view of the above, this study becomes an alternative that allows to contribute to future work.

KEYWORDS: *Forecast of demand, electric power consumption, forecast errors.*

INTRODUÇÃO

O consumo de energia elétrica é um dos principais indicadores do desenvolvimento econômico e do nível de qualidade de vida de qualquer sociedade (BRASIL, 2008). Isso porque a demanda energética reflete tanto o ritmo de atividade industrial, comercial e de serviços, quanto à capacidade da população para adquirir bens e serviços (LIN, MOUBARAK, 2014; SORRELL, 2015). A Empresa de Pesquisa Energética (EPE) aponta que o Brasil é o sétimo maior consumidor mundial de energia elétrica, destaca ainda que os municípios que mais consomem energia são aqueles que apresentam maior concentração de atividades industriais (BRASIL, 2017).

Neste sentido, a crescente demanda do consumo de energia elétrica, requer um planejamento/estudo que seja capaz de projetar quais serão as tendências de consumo energético no futuro. Pesquisas recentes como plano decenal de expansão de energia, anuário estatístico de energia elétrica entre outras, recorrem às técnicas de projeção de demanda, com objetivo de planejar a expansão de energia, além de propor aplicações nos estudos do planejamento da operação (NEJAT et al., 2015; SOCCOL et al., 2016).

Diante do exposto, a previsão de demanda é uma importante variável para as organizações, servem como guia para o planejamento estratégico. No âmbito do Planejamento e Controle da Produção (PCP), as previsões são um dos principais dados de entrada para as decisões do PCP. Segundo Slack et al (2009) planejamento e controle é a atividade de decidir sobre o melhor emprego dos recursos de produção, assegurando, a execução do que foi previsto.

Sendo assim, o objetivo deste artigo é avaliar a utilização de quatro diferentes métodos de previsão de demanda para o consumo industrial de energia elétrica no Brasil e identificar o mais aderente a ser utilizado, levando em consideração o resultado do erro médio absoluto apresentado. Para tanto, serão empregados modelos de previsão de demanda de séries temporais: (A) Média Móvel, (B) Média Móvel Ponderada, (C) Suavização Exponencial e (D) Autoregressivo de Média Móvel (ARMA). Especificamente pretende-se verificar a

estacionariedade das séries, calcular o percentual do erro médio de cada um dos métodos, e escolher o modelo mais aderente para a previsão da supracitada série.

REVISÃO BIBLIOGRÁFICA

Métodos para a previsão de demanda

Todo sistema de produção tem como objetivo atender a demanda, que se trata da quantidade de um bem que os consumidores desejam adquirir, expressa ao longo do tempo. É ela que determina o momento da oferta, se a indústria tiver uma clara noção da demanda futura, poderá ajustar seu sistema de produção em tempo hábil, de modo a atendê-la quando esta, de fato, se concretizar (BEZERRA, 2013).

O sistema de previsão é o conjunto de procedimentos de coletas, tratamento e análise das informações que visa gerar estimativas futura. É importante que as organizações saibam utilizar as ferramentas disponíveis para conseguir antecipar a demanda futura com precisão (CORREA, et al., 2013).

A previsão é uma projeção para um período futuro, baseado em planos e diretamente proporcional a ocorrência de determinados eventos, com probabilidade de ocorrer durante um período específico (BIAGIO; BATOCCHIO, 2012).

De acordo com Lustosa et al. (2008), os métodos de previsão de demanda são classificados em dois grupos. No primeiro, estão os métodos qualitativos, baseados em conceitos e críticas pessoais. O segundo grupo é composto pelos métodos quantitativos, baseados em técnicas estatísticas (LUSTOSA, et al., 2008).

A previsão de demanda pelo método quantitativo é composta por vários modelos de projeção, dentre eles, a média móvel simples, média móvel ponderada, suavização exponencial e autoregressivo de média móvel (ARMA). Existem várias técnicas disponíveis para se realizar a previsão de demanda, sendo que, estas podem ser usadas em diversas circunstâncias, a depender de alguns fatores, como disponibilidade de dados, tempo, recursos e horizonte de previsão. Essas técnicas podem ser classificadas em qualitativas ou quantitativas (ALBERTIN; PONTES, 2016).

Muitos métodos quantitativos baseiam-se na análise de séries temporais, neste contexto, Corrêa e Corrêa (2012) destacam que a decomposição de série temporal é composta em três componentes:

- Tendência: É a orientação geral, para cima ou para baixo, dos dados históricos;
- Ciclicidade: Padrões de variação dos dados de uma série que se repetem a cada intervalo de tempo (longo prazo), no entanto, a variação cíclica em curto prazo (inferior a um ano) é denominada como sazonalidade;

Aleatoriedade: São os “erros” ou variações da série histórica de dados que não são devidas a variáveis presentes no modelo de previsão.

Média Móvel: Simples e Ponderada

A previsão de demanda a partir do conceito de média móvel tem por finalidade identificar o valor previsto para a demanda do próximo período. Sendo assim, o cálculo é igual à média aritmética dos últimos “n” períodos. Matematicamente, a previsão de demanda por Média Móvel Simples é determinada pela Equação (1).

$$F_t(t + 1) = \frac{D_t + D_{t-1} + \dots + D_{t-n+1}}{n} \quad (1)$$

Onde D_t representa a demanda real no período t e n , a quantidade de períodos considerada.

Ressalta-se que a decisão de qual será o número de períodos utilizados no cálculo é fundamental para a previsão, sendo que, quanto maior “n”, menor é a variação da previsão. (LUSTOSA, et al., 2008).

A média móvel ponderada consiste em considerar a importância dos períodos da previsão atribuindo-lhes pesos distintos. (RITZMAN; KRAJEWSKI, 2004). O método matemático que ilustra o modelo de média móvel ponderada e determinado pela Equação (2).

$$P_{(j)} = P_1 D_1 + P_2 D_2 + \dots + P_n D_n \quad (2)$$

Onde:

P_j = previsão para o período j ;

P_i = peso atribuído ao período i ;

D_i = demanda do período i .

O modelo de previsão de demanda pela média móvel ponderada é uma variação da média móvel simples, a diferença é que neste modelo considera um peso maior para o último período de demanda, um peso ligeiramente menor para o penúltimo período e assim por diante até o último período utilizado para a estimativa. Isso quer dizer que os valores da demanda dos períodos mais próximos, são considerados mais importantes, na definição da estimativa que os períodos mais distantes. Normalmente, se utiliza a soma dos pesos igual a um, para que não seja necessário dividir o resultado pela soma dos pesos (PEINADO; GRAEML, 2007).

Suavização Exponencial

De acordo com Corrêa et al (2001) o método de suavização exponencial é similar ao da média móvel ponderada, com a diferença de que são utilizados todos os valores históricos, com coeficientes de ponderação que decrescem exponencialmente. Para Fernandes e Godinho (2010) o método da suavização exponencial fornece a previsão para o próximo período como sendo a previsão para o período atual. É dado um peso α a esse erro.

Suavização exponencial é um método baseado na média móvel ponderada no qual atribui-se peso maior as demandas recentes do que as demandas iniciais. A previsão por suavização requer somente três tipos de dados, a previsão do último período, a demanda para o período atual e o parâmetro de aproximação alfa (α). Matematicamente o modelo pode ser escrito de acordo com a Equação 3.

$$P_{(j)} = \alpha D + (1 - \alpha)D_{j-1} \quad (3)$$

Onde:

P_j = previsão para o período j ;

D = demanda do período;

α = constante de suavização,

D_{j-1} = previsão calculada no último período.

O valor de α determina o equilíbrio entre a sensibilidade das previsões, as mudanças da demanda e a estabilidade das previsões. Valores próximos de um enfatizam níveis mais recentes de demanda e resultam em previsões mais sensíveis a alterações. Valores próximos

de zero tratam a demanda passada de modo mais uniforme e resultam em previsões mais estáveis (RITZMAN; KRAJEWSKI, 2004).

Modelo Autoregressivo de Média Móvel – ARMA

De acordo com Azevedo (2010) o modelo ARMA é a combinação dos modelos autoregressivo (AR) e de média móvel. Afirma ainda que o processo ARMA forma uma classe útil para descrever dados de séries temporais.

Morettin e Tolo (2006) afirmam que os modelos ARMA é a solução adequada para séries temporais com um número não muito grande de parâmetros. O modelo ARMA é dado pela Equação 4.

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \dots - \theta_q a_{t-q} \quad (4)$$

Onde:

ϕ_i = Parâmetros da estrutura Auto Regressiva, $i=1, \dots, p$

θ_i = Parâmetros da estrutura média móvel, $i=1, \dots, q$

a_t = Ruído branco

Erros de Previsão

Os erros de previsão são os desvios entre a demanda real observada e a previsão. Serve de parâmetros para a escolha do modelo mais apropriado do conjunto de dados, este critério sugere que o melhor modelo é o que apresenta o menor erro de previsão (LUSTOSA et al 2008).

No processo de previsão de demanda, ao medir matematicamente se o modelo é confiável é um aspecto importante a ser considerado. Para Lemos (2006), a assertividade da previsão, determina se o modelo de previsão representa a série de dados já conhecida, pode ser utilizada inclusive para a escolha entre diferentes modelos de previsão. Os Erros de Previsão são dados pela Equação 5.

$$E_t = D_t - P_t \quad (5)$$

Onde:

E_t = Erro de Previsão para o período t

D_t = Valor Real

P_t = Valor previsto

De acordo com Morettin e Toloi (2006), os métodos de avaliação da previsão de demanda devem levar em consideração dois aspectos fundamentais do erro calculado:

- i. Valor Absoluto do Erro: utilizado para percepção de quão grande é o risco e o impacto de decisões relacionadas a essa previsão.
- ii. Valor Relativo à Demanda Real: este aspecto tem como função a comparação entre previsões por diferentes métodos e também a comparação entre previsões de séries que tenham seus valores absolutos muito discrepantes.

Esses aspectos são considerados em muitos métodos de avaliação de previsão e, para este artigo que tem por objetivo a comparação dos métodos da previsão de demanda, será utilizado o erro médio absoluto dos modelos.

O erro médio (EM) é a média do erro de previsão para o período que se deseja analisar, é calculado pela Equação 6.

$$EM = \frac{\sum_{t=1}^n (D_t - P_t)}{n} \quad (6)$$

Onde:

D_t = É o valor observado no período t ;

P_t = É o valor previsto para o período t .

MATERIAIS E MÉTODOS

Para este estudo foi utilizado os dados de consumo de energia elétrica brasileira no setor industrial, no qual foram extraídos do sitio do Instituto de Pesquisa Aplicada (IPEA), referente ao período de abril de 2007 a janeiro de 2017.

As técnicas de previsão de demanda utilizadas foram: média móvel, média móvel ponderada, suavização exponencial e autoregressivo de média móvel (ARMA). Para a análise dos

resultados foi necessário plotar os dados no gráfico e identificar os erros causados pela aleatoriedade e flutuação da série.

Para se trabalhar com os modelos de previsão citados anteriormente foi necessário verificar se os dados são estacionários ou não. Modelos estacionários são aqueles que assumem que o processo está em “equilíbrio”. Para detectar a estacionariedade de uma série, o comportamento temporal pode ser analisado graficamente, buscando padrões (a) e (b) ou utilizar o teste de correlação de Spearman, através da Equação 7.

$$p = 1 - \frac{6T}{N(N^2-1)} \quad (7)$$

Onde T é calculado pela Equação 8.

$$T = \sum_{t=1}^N [R_t - t]^2 \quad (8)$$

Considera-se que a série seja estacionaria se o teste de correlação de Spearman for negativo. Através da análise do erro médio é definido qual modelo é o mais aderente para a série temporal estudada, ressalta-se que quanto menor for o erro, mais adequado é o modelo. Na seção a seguir são apresentados os a discussão dos resultados.

RESULTADOS E DISCUSSÃO

A Tabela 1 apresenta as estatísticas descritivas para o consumo energético industrial no Brasil entre 2007 e 2017. A assimetria foi negativa, apontando uma distribuição assimétrica à esquerda. A estatística referente à curtose, que mede o achatamento da distribuição, está menor que 3 (valor normal), indicando uma distribuição com achatamento da curva, trata-se, portanto, de uma distribuição da classe leptocúrtica (curva de frequência mais fechada que a normal).

Tabela 1. Estatísticas descritivas do consumo energético industrial

Estatísticas	Energia
Média	14.708
Mediana	14.876
Desvio Padrão	784,830
Variância	615.958,530
Curtose	0,265
Assimetria	-0,795
Amplitude	3.722

Fonte – Resultado da pesquisa, 2017.

Para detectar a estacionariedade da série, foi utilizado o teste de correlação de Spearman no qual obteve o resultado de -23,61%, e com isso pode-se afirmar que a série é estacionária. Uma série temporal é estacionária, quando esta desenvolve no tempo ao redor de uma média constante, suas propriedades estatísticas não mudam com o tempo, refletindo alguma forma de equilíbrio estável. A partir do resultado de correlação, é definido o valor do erro médio dos modelos de previsão de demanda de séries temporais: média móvel, média móvel ponderada, suavização exponencial e por fim o método ARMA.

A Tabela 2 mostra o resultado referente ao erro médio absoluto dos modelos citados anteriormente. Nota-se que o modelo de média móvel simples apresenta o maior valor do erro médio. Os dados levantados sobre o produto estudado demonstra comportamento sazonal. Por ser um produto de grande relevância e não possuir demanda estável, a média móvel deixa de ser a melhor alternativa, valendo tal premissa também para a média móvel ponderada, apesar de possuir o segundo menor valor do erro. Desta maneira, considera-se o modelo ARMA mais adequado para a previsão de demanda energética industrial no Brasil dentre os estudados, uma vez que o modelo apresentou o menor valor do erro médio, tornando o modelo aderente para o tipo de série estudada. De acordo com Agência Nacional de Energia Elétrica (ANEEL), os modelos de previsão de demanda são de livre escolha das distribuidoras, entretanto, o resultado das previsões está sujeito à validação pela ANNEEL (BRASIL, 2015).

O modelo do sistema elétrico vem passando por mudanças com o aumento do uso de fontes de geração renovável, que, por sua vez, dependem da previsão de um determinado recurso. Sendo assim, os modelos de previsão podem utilizar variáveis locais (climáticas, sociais, econômicas, etc.) que possam ter um impacto direto ou indireto na demanda ou no comportamento de geração de energia (HERNANDEZ et al, 2014).

Tabela 2. Erro médio absoluto dos métodos quantitativos de previsão

Método de Previsão	Erro Mensal	Erro Anual
Média Móvel	353	654
Média Móvel Ponderada	313	597
Suavização Exponencial	331	576
ARMA – Auto Regressivo	297	483

Fonte – Resultado da pesquisa, 2017.

O gerenciamento da demanda de energia consiste em planejar, implementar e monitorar atividades de utilização de energia. A gestão da demanda de energia é necessária para a alocação adequada dos recursos disponíveis. Durante a última década, várias técnicas novas estão sendo usadas para o gerenciamento da demanda de energia para prever com precisão as futuras necessidades energéticas (SGANTHI; SAMUEL, 2012).

A estatística contribui no planejamento e tomada de decisão das organizações, com isso, a análise descritiva é um importante fator a ser considerado. Neste caso, as estatísticas descritivas fornecem um diagnóstico inicial ao planejamento energético.

Neste caso, as estatísticas descritivas fornecem um diagnóstico inicial ao planejamento energético. O Gráfico 1 compara as demandas reais e previstas acerca do consumo de energia elétrica industrial no Brasil, com base nos modelos de média móvel, ponderada, suavização exponencial e vetores da classe ARMA.

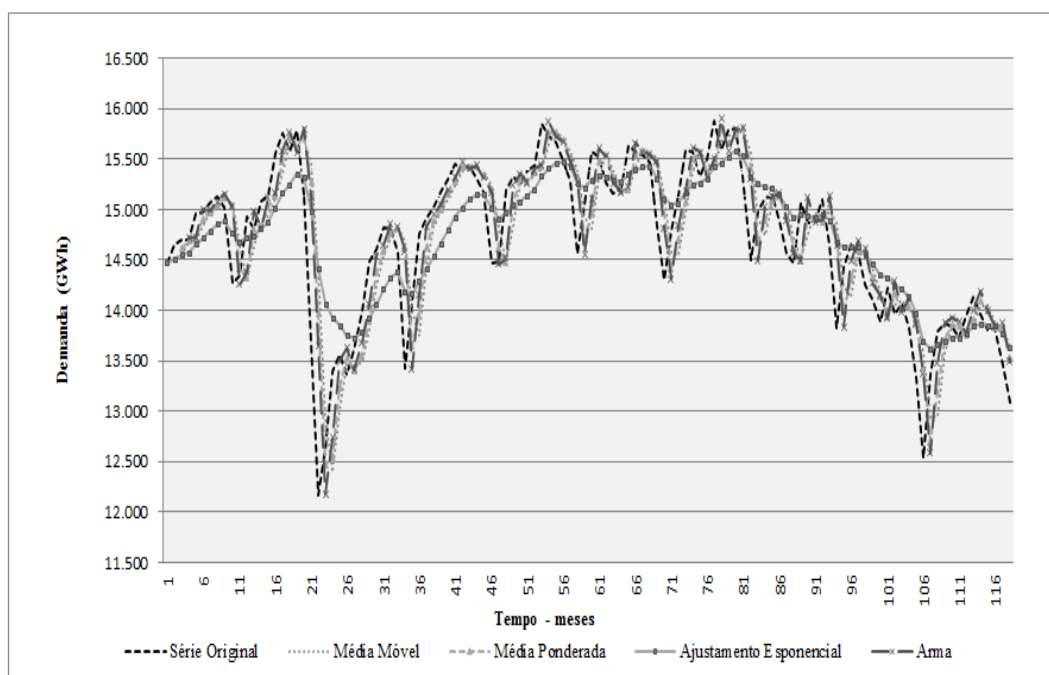


Gráfico 1 - Demandas reais e previstas do consumo industrial de energia elétrica.

Fonte – Resultado da pesquisa, 2017.

Percebe-se que a variação do consumo industrial de energia elétrica tem natureza complexa, devido a fatores exógenos, ou seja, é comum observar a existência de comportamento que caracterizam a sazonalidade em diferentes horizontes de observações.

É possível observar o comportamento sazonal da série temporal do consumo de energia elétrica, fatores econômicos, climáticos, sociais, políticos entre outros, afetam diretamente a demanda energética.

A desaceleração na economia nacional e internacional, fruto da crise financeira de 2008, vem produzindo efeitos diretos e indiretos no mercado de energia elétrica brasileiro, gerando reflexo imediato na demanda energética industrial (BRASIL, 2017). Os principais valores observados na série estão associados a fatores que afetam a demanda energética. Devido às incertezas do mercado nos períodos de crises, há uma redução na demanda causando reflexos no consumo de energia industrial (BRASIL, 2017).

Outro fator que causa efeito na demanda energética é o impacto climático, uma vez que, este fenômeno provoca níveis críticos nos reservatórios das usinas hidrelétricas, afetando o fornecimento de energia. As mudanças de temperaturas são capazes de alterar o nível, tempo e distribuição da demanda por eletricidade. As alterações no clima afetam a eficiência e a confiabilidade do fornecimento de energia (HUBACK et al, 2016). O Gráfico 2 apresenta a projeção da demanda industrial energética no Brasil para o ano de 2017 utilizando os métodos quantitativos de previsão abordados pela pesquisa.

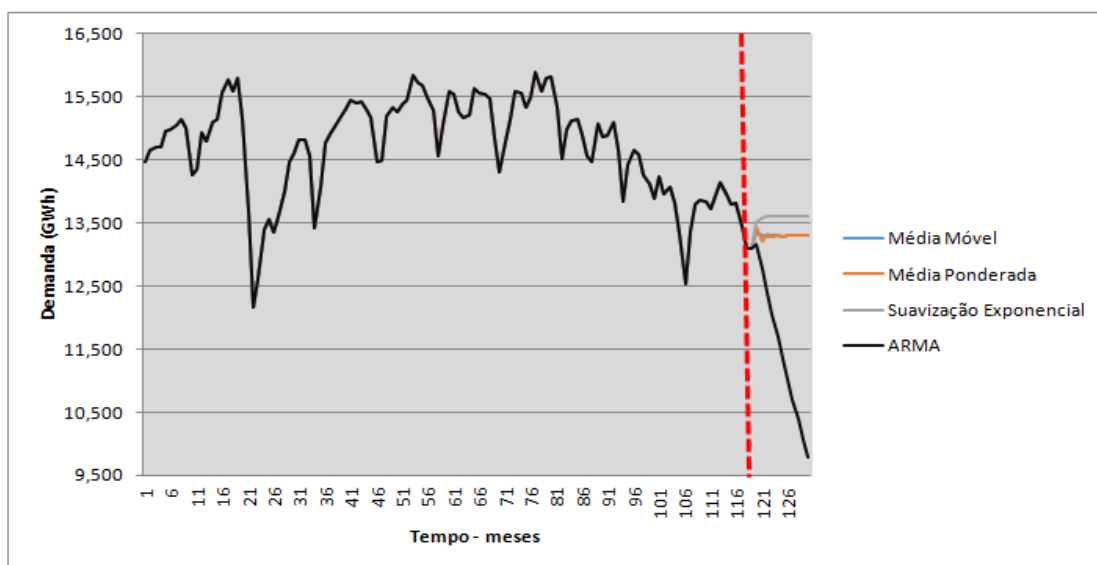


Gráfico 2 – Projeção da demanda industrial energética

Fonte – Resultado da pesquisa, 2017.

Nota-se que o modelo de média móvel simples, seguido pelo de média móvel ponderada, demonstra que o consumo de energia elétrica industrial terá um pequeno pico na série se mantendo estável nos demais meses subsequentes. A suavização exponencial apresenta uma tendência de crescimento inicial, mantendo uma regularidade linear nos demais períodos. Já o método ARMA, apresentará redução na demanda energética para os períodos futuros. O supracitado gráfico pode ser uma boa proxy para a aceleração ou não da economia brasileira no ano de 2017. Percebe-se que todos os modelos projetam uma estabilidade ou decréscimo do consumo industrial de energia em 2017.

O consumo de eletricidade apresenta uma previsão de redução, sendo o setor industrial o principal contribuinte, seguido pelos setores residencial e comercial (BRASIL, 2017).

Assim, pode-se observar que o método ARMA se alinha a pesquisas recentes, pois o mesmo aponta uma redução futura no consumo industrial de energia elétrica em igualdade com o plano de expansão energética e o estudo de projeção de demanda.

As séries temporais aqui apresentadas foram utilizadas para validação dos modelos de previsão de demanda propostos. Os métodos de previsão sugerem que o comportamento futuro da série possa ser estimado baseado no comportamento ocorrido no passado. A análise do erro médio absoluto foi utilizada para mensurar qual o modelo é o mais aderente para a série estudada, considerando que, quanto menor o valor do erro, mais eficaz é o modelo.

CONCLUSÃO

Este artigo teve como objetivo comparar o método mais adequado de previsão de demanda para o consumo de energia elétrica industrial no Brasil. Observou que o produto estudado tem comportamento sazonal e através da análise do erro médio dos métodos quantitativos, foi definido qual modelo de previsão é o mais aderente para a série.

Os modelos utilizados foram os de média móvel simples, média móvel ponderada, suavização exponencial e autoregressivo de média móvel (ARMA). Dos resultados obtidos na análise de erros, o método ARMA apresentou melhor desempenho. Isso quer dizer que o modelo obteve o menor valor do erro causado pela aleatoriedade e flutuação das series temporais.

Por mais acurada que seja a técnica de previsão utilizada, sempre existirão erros. Fatores imprevisíveis como crise econômica, impacto climático, sociais, políticos, entre outros, podem fazer com que as previsões fiquem além do esperado. Por isso, deve-se estar atento ao mercado e preparado para as distorções de valores das previsões.

Recomenda-se como tema de trabalhos futuros o cálculo de formulações mais robustas acerca da determinação dos erros preditivos do modelo, além do desenvolvimento de modelos econométricos da classe SAR, uma vez que se constatou a sazonalidade mensal da série histórica do consumo de energia no Brasil.

REFERÊNCIAS

ALBERTIN, Marcos R.; PONTES, Heráclito L. J.. **Administração da Produção e Operações**. Curitiba: Intersaberes, 2016.

ATLAS DE ENERGIA ELETRICA DO BRASIL. **Energia no Brasil e no mundo (2008)**. Disponível em: <http://www2.aneel.gov.br/arquivos/pdf/atlas_par1_cap2.pdf>. Acesso em 26 abr. 2017.

AZEVEDO, Túlio M. A. **Previsão de series de Impostos do Município de Belo Horizonte**. Belo Horizonte: UFMG, 2010. Programa de Pós-Graduação em Ciências Exatas, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

BIAGIO, Luiz A.; BATOCCHIO, Antônio. **Plano de Negócios: Estratégia para Micro e Pequenas Empresas**. 2ed. São Paulo: Manole, 2012.

BEZERRA, Cicero A.. **Técnicas de Planejamento, Programação e Controle da Produção**. Curitiba: Intersaberes, 2013.

BRASIL, Agência Nacional de Energia Elétrica. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**. ANEEL, 2015. Disponível em: <http://www2.aneel.gov.br/arquivos/PDF/PRODIST%20-%20M%C3%B3dulo%202_Revisao_6.pdf> Acesso em 02 jul. 2017.

BRASIL, Ministério de Minas e Energia, Empresa de Pesquisa Energética. **Plano Decenal de Expansão de Energia 2019**. Brasília: MME/EPE, 2010. Disponível em: <http://www.epe.gov.br/PDEE/20101129_2.pdf>. Acesso em 24 jun. 2017.

BRASIL, Ministério de Minas e Energia, Empresa de Pesquisa Energética. **Projeções da demanda de energia elétrica para o plano decenal de expansão de energia 2008-2017**. Brasília: MME/EPE, 2010. Disponível em: <http://www.epe.gov.br/mercado/Documents/S%C3%A9rie%20Estudos%20de%20Energia/20080416_3.pdf>. Acesso em 30 abr. 2017.

BRASIL, Ministério de Minas e Energia, Empresa de Pesquisa Energética, Operador Nacional do Sistema Elétrico. **Estudo da Demanda: Projeções da Demanda de Energia Elétrica 2016-2020**. Rio de Janeiro: MME/EPE/ONS, 2016. Disponível em: <http://www.ons.org.br/download/operacao/previsao_carga/NT_ONS-EPE-1Revisao_Quadrimestral_2016_2020.pdf>. Acesso em 02 jul. 2017.

CORRÊA, Henrique L.; GIANESI, Irineu G. N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção**. 4ed. São Paulo: Atlas, 2001.

CORRÊA, Henrique L.; CORRÊA, Carlos A.. **Administração de Produção e Operações: Manufatura e Serviços: uma abordagem estratégica**. 3ed. São Paulo: Atlas, 2012.

CORRÊA, Henrique L.; GIANESI, Irineu G. N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção**. 5ed. São Paulo: Atlas, 2013.

FERNANDES, Flavio C. F.; GODINHO, Moacir F.. **Planejamento e Controle da Produção: dos fundamentos ao essencial**. São Paulo: Atlas, 2010.

HERNANDEZ, Luis et al. A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings. **IEEE Communications Surveys & Tutorials**, v. 16, n. 3, p. 1460-1495, 2014.

HUBACK, Vanessa B. S.; CASTRO, Nivalde J.; DANTAS, Guilherme A.; SILVA, Patrícia P.; ROSENAL, Rubens; MAGALHÃES, Maria A. **Mudanças climáticas e os impactos sobre o setor de energia elétrica**. Congresso Brasileiro de Planejamento Energético, Gramado, RS, Brasil, 2016.

IPEA - INSTITUTO DE PESQUISA ECONÔMICA APLICADA. **Consumo de energia elétrica no setor indústria**. Disponível em: <www.ipeadata.gov.br>. Acesso em 20 de mar. 2017.

LEMONS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. Tese de Mestrado, UFRGS, Porto Alegre, RS, Brasil, 2006.

LIN, Boqiang; MOUBARAK, Mohamed. Estimation of energy saving potential in China's paper industry. **Energy**, v. 65, p. 182-189, 2014.

LUSTOSA, Oliveira; MESQUITA, Marcos A.; QUELHAS, Osvaldo; OLIVEIRA, Rodrigo. **Planejamento e Controle da Produção**. Rio de Janeiro: Elsevier, 2008.

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

NEJAT, Payam et al. A global review of energy consumption, CO₂ emissions and policy in the residential sector (with an overview of the top ten CO₂ emitting countries). **Renewable and sustainable energy reviews**, v. 43, p. 843-862, 2015.

PEINADO, Jurandir; GRAEML, Alexandre R.. **Administração da Produção: Operações industriais e de serviços**. Curitiba: Unicenp, 2007.

RITZMAN, Larry; KRAJEWSKI, Lee J.. **Administração da Produção e Operações**. São Paulo: Prentice Hall, 2004.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção**. 3ed. São Paulo: Atlas, 2009.

SOCOL, Francisco Junior et al. Desafios Para Implementação da Geração Distribuída de Energia no Brasil: Uma Revisão Integrativa da Literatura. **Brazilian Journal of Production Engineering-BJPE**, v. 2, n. 3, p. 31-43, 2016.

SORRELL, Steve. Reducing energy demand: A review of issues, challenges and approaches. **Renewable and Sustainable Energy Reviews**, v. 47, p. 74-82, 2015.

SUGANTHI, L.; SAMUEL, Anand A. Energy models for demand forecasting—A review. **Renewable and sustainable energy reviews**, v. 16, n. 2, p. 1223-1240, 2012.