

PREVISÃO DO PREÇO DA ENERGIA: UMA APLICAÇÃO DA METODOLOGIA BOX-JENKINS

Gabriel Alves Rodrigues (UNIFEI)
garodrigues@hotmail.com

Paulo Henrique Paulista (UNIFEI)
paulohpeca@yahoo.com.br

João Batista Turrioni (UNIFEI)
turrioni@unifei.edu.br



A energia elétrica alavancou todos os campos da sociedade e tornou-se um produto de extremo valor. Seu mercado é hoje um dos mais importantes já que, influencia diretamente em todos os outros setores sociais. Porém, como os meios e produção de energia são muito diversificados e dependem de uma série de fatores, a previsão do preço deste produto tornou-se um problema para as empresas geradoras, distribuidoras, para os consumidores e investidores visto que, fica muito difícil traçar os rumos do mercado sem esse dado.

Este trabalho aplicou a metodologia Box-Jenkins na série temporal de preço da energia elétrica a fim de analisá-la e obter previsões do preço futuro. Após a análise gráfica, o modelo apontado como mais adequado foi o SARIMA(1,0,1)(1,2,1)I₂. Porém, este não ofereceu previsões tão precisas já que foram comparadas com valores referentes a um longo período de estiagem.

Palavras-chaves: Métodos de previsão, preço da energia, Box-Jenkins,

1. Introdução

A energia elétrica é uma das mais importantes tecnologias produzida pelo homem e, sem ela, não seria possível o desenvolvimento em diversas áreas do conhecimento humano. Com isso, seus métodos de produção e distribuição vêm sendo aprimorados ao longo dos anos e ela se tornou um produto de extremo valor. Isso porque, já a algumas décadas, a energia elétrica é indispensável para o desenvolvimento econômico de qualquer sociedade.

Como os meios de produção de eletricidade são muito variados e alguns dependem de condições climáticas, há uma grande dificuldade por parte dos produtores de energia elétrica em determinar seu valor de comercialização, visto que, após a reforma do setor energético em alguns países (Inglaterra, Estados Unidos, Chile, Brasil, entre outros), este mercado se tornou extremamente complexo. Segundo Niimura (2006), a previsão de preço é uma questão complexa e que envolve muitos fatores e atividades relacionadas ao mercado de energia, entre eles: o design do mercado, tarifas e outras políticas.

Segundo Garcia et al (2005), a previsão de preços está se tornando cada vez mais relevante para os produtores e consumidores do novo e competitivo mercado de energia. Isso por que essas previsões são necessárias para ditar os rumos do mercado como: as ações dos investidores e os contratos de distribuição.

Com essa necessidade, muitas pesquisas nessa área surgiram nos últimos anos onde se passou a estudar a aplicação de métodos de previsão de preço no mercado de energia elétrica.

Este trabalho apresenta uma descrição do mercado de energia elétrica, faz uma breve abordagem sobre os métodos de previsão e aplica a metodologia Box-Jenkins a fim de realizar previsões do preço de comercialização da energia elétrica e analisa sua eficiência em tal aplicação.

2. O Mercado de Energia Elétrica

Até os anos 80, o setor elétrico era tido como monopólio do governo. Porém, nesse período, a política de privatização foi adotada pela grande maioria dos governos ocidentais, desencadeando uma série de reformas, e o setor elétrico foi um dos atingidos (MEDEIROS, 2003). Essa tendência teve início nos países da Europa e nos Estados Unidos, e segundo Bermann & Longo (2003), o objetivo inicial era permitir que o governo se concentrasse mais em suas ações políticas e, regulamentar o setor, transferindo as responsabilidades de administração e investimentos para o setor privado.

Para a implantação dessa nova estrutura no Brasil, foi contratada uma empresa de consultoria internacional que, através de um estudo determinaria a forma mais adequada e as medidas adotadas para estruturar o modelo. A partir de 1995 uma série de leis foram sancionadas a fim de regulamentar esse modelo.

Essa nova legislação promoveu uma desverticalização do sistema, onde houve a separação dos diversos segmentos componentes do sistema produtivo de energia. Enquanto as atividades de transmissão e distribuição ficaram ainda em parte como monopólios naturais, as atividades de geração e comercialização passaram a constituir um concorrido mercado, disputado por empresas privadas. Durante esse processo, ocorreu também a privatização de grande parte das empresas de transmissão e de algumas empresas

geradoras, eliminando responsabilidades do estado e evitando que este participasse da concorrência. Incentivou-se também o livre acesso às redes de transmissão e a criação de Mercados Atacadistas de Energia (MAE) ou mercados spot – espécie de leilões de potência ou energia – que serviriam de base para os preços do setor (MEDEIROS, 2003).

Nos mercados livres de energia a contratação do serviço é estabelecida entre as empresas dos diversos segmentos através de contratos bilaterais, que especificam o valor e o montante acordado durante sua vigência. Esses contratos visam proteger as partes mediante a grande variação de preço de energia no MAE (ANDRADE & RAMALHO, 2002).

Outro fator importante a se destacar é o surgimento de diversos agentes, constituintes desse novo mercado competitivo como, por exemplo, o operador do sistema; regulador; planejador da expansão; financiador; e comercializador (responsável pelas transações comerciais no novo mercado de eletricidade); além das figuras dos consumidores livres e dos produtores independentes. Outros agentes tiveram suas atribuições modificadas, como os agentes de geração (que passaram a ter uma regulação mínima), transmissão e distribuição (MEDEIROS, 2003).

Davidson et al (2002) relacionam dois motivos para a alta volatilidade dos preços da energia elétrica: o fato da energia elétrica ter suas especificidades, pois a mesma não pode ser armazenada em grandes quantidades, e a demanda deve estar em equilíbrio constante com a produção.

Outro fator que influencia na variação do preço de energia é o fato do sistema elétrico brasileiro ser interligado. Como a maior parte da eletricidade nacional é produzida por hidrelétricas, estas se concentram em áreas específicas, o que encarece a distribuição para determinadas regiões. Assim, a fim de redistribuir melhor estes gastos, os preços são tratados diferentemente para cada região, dividindo o país em: sudeste/centro-oeste (SE/CO); sul (S); nordeste (NE); norte (N).

Com isso, visto a complexidade do sistema elétrico nacional e as limitações nos processos de produção e distribuição, percebe-se a dificuldade e a importância de se obter boas previsões dos preços futuros de energia. Tal processo facilitaria os processos de tomada de decisão.

3.Os Métodos de Previsão

Os métodos de previsão se constituem em um conjunto de técnicas de análise de informações que visam prever, com maior precisão possível, futuros resultados. Essas técnicas podem ser desenvolvidas através de análises qualitativas, que se baseiam em julgamentos de especialistas ou através da análise quantitativa, realizada pela observação e processamento de dados históricos com auxílio de modelos matemáticos (ZAN & SELLITO, 2007). Alguns autores, como Niimura (2006), desconsideram os métodos qualitativos, não considerando sua importância em alguns tipos de fenômenos a serem analisados.

As técnicas baseadas nas opiniões de especialistas podem ser moldadas de acordo com o fenômeno a ser analisado. Porém, uma das principais técnicas qualitativas de previsão é o modelo Delphi, uma metodologia rápida e barata, que não permite utilizar a análise estatística dos dados. É uma técnica que visa refinar a opinião de especialistas através de procedimentos criteriosos e aplicação iterativa de questionários (MORICOCHI et al, 1995).

Os modelos quantitativos, por sua vez, são divididos em: métodos casuais que, baseados em processos de simulação e dados históricos para variáveis dependentes e independentes, procuram relações aleatórias entre fatores que podem influenciar na previsão (ZAN & SELLITO, 2007); e métodos analíticos de séries temporais que buscam através de modelos matemáticos detectar e relacionar variáveis que influenciam diretamente nos fenômenos analisados. Segundo Niimura (2006) e Gonzáles (2005), a análise de séries temporais pode ser feita por métodos estacionários (métodos de regressão linear e transferência de função como o Auto Regressive Moving Averages (ARMA) e o Generalized Auto Regressive Conditional Heteroskedasticity (GARCH) e não estacionários como por exemplo processos computacionais de aprimoramento contínuo usando a lógica Fuzzy.

As séries temporais são conjuntos de dados ordenados no tempo e podem ser divididas em quatro elementos componentes: a tendência, que verifica o sentido de deslocamento da série ao longo do tempo; o ciclo, movimento ondulatório que ao longo de vários anos tende a ser periódico; a sazonalidade, que tem a duração de curto prazo, inferior a um ano; os acontecimentos aleatórios de difícil modelagem. A separação da série nessas componentes facilita a compreensão do fenômeno, a escolha do método a ser aplicado e apresenta possíveis necessidades de adaptações no modelo. Nem todos os fenômenos podem ser decompostos nestes exatos quatro componentes, visto que podem não apresentar algum deles ou outras variações (RIBEIRO et al, 2003; BRUM et al, 2005).

4.A metodologia Box-Jenkins

É um método quantitativo, desenvolvido na década de 60, que reúne técnicas eficientes de análise de séries temporais existentes a fim de construir modelos que descrevam, com precisão e de forma confiável, o processo gerador da série temporal, proporcionando dessa forma previsões acuradas de valores futuros (FÁVERO & OLIVEIRA, 2002).

Os modelos Box-Jenkins são genericamente conhecidos como Auto Regressive Integrated Moving Averages (ARIMA) e resultam da combinação de três componentes, espécies de filtros: componente auto-regressivo (AR); componente de integração (I); componente de médias móveis (MA). Eles são variáveis matemáticas que visam detectar o estado de correlação ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões (RIBEIRO et al, 2003).

Esta metodologia estima modelos de séries temporais da forma:

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (1)$$

Nesta equação temos que o termo α_0 representa uma constante no modelo estimado, α_1 até α_p são parâmetros que ajustam os valores passados de y_t do instante imediatamente anterior até o mais distante representado por p . Os valores de ε representam uma seqüência de choques aleatórios e independentes uns com os outros, ε_t é uma porção não-controlável do modelo e é chamado normalmente de ruído branco. Os parâmetros β_1 até β_q possibilitam escrever a série em função dos choques passados (FÁVERO & OLIVEIRA, 2002).

A construção dos modelos Box-Jenkins se dá de forma iterativa e se baseia nos próprios dados. Anderson (1976) nos diz que são três as etapas de para construção do modelo:

- a) Identificação: identificar, através das relações de autocorrelação (ACF), qual das técnicas do modelo melhor descrevem o comportamento da série.
- b) Estimação: consiste em estimar os parâmetros do componente auto-regressivo, do componente de médias móveis e a variância do ruído branco.
- c) Verificação: testar o modelo desenvolvido e verificar se este descreve adequadamente o comportamento dos dados.
- d) Previsão: ocorrem através da substituição das variáveis das equações de cada modelo, apresentadas em seguida (seção 4), e a da indicação do número de passos a frente que se quer prever. O desenvolvimento matemático do processo de previsão não será apresentado neste trabalho, visto que essa etapa será realizada pelo software MINITAB 15.

Nem sempre é fácil realizar estas etapas, podendo ocorrer erros no processo de construção ou até mesmo a inadequação da série a esse tipo de análise. Assim, deve-se reiniciar a estruturação ou até mesmo buscar outros métodos que descrevam com maior eficácia o fenômeno analisado. Porém, uma vez modelado o comportamento da série, inicia-se o processo de realização de previsões.

4.1 Modelo Estacionário

Quando o processo está em equilíbrio, pode-se aplicar um modelo estacionário. Se suas média e variância se mantêm constantes ao longo do tempo, e a função de auto-covariância depende apenas da diferença dos instantes de tempo, esse processo é levemente estacionário. Se todos os elementos não variarem no tempo, ele é fortemente estacionário.

4.1.1 Modelo auto-regressivo

Em um modelo auto-regressivo, a regressão dos dados passados e o ruído aleatório descrevem a série de valores:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (1)$$

Onde: Z_t = série de dados históricos; ϕ_i = é o parâmetro que descreve como Z_t se relaciona os valores passados $Z_{t-1}, 2, 3, \dots, p$; ε_t = ruído aleatório;

A representação mais simples desse modelo é o AR (1), apresentando ordem um ($p=1$):

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t \quad (2)$$

A condição de estacionariedade para esse modelo é que $-1 < \phi_1 < 1$.

Nesse modelo, a função de auto-correlação decai exponencialmente, porém, quando o valor de ϕ_1 é negativo, ela apresenta alternância entre sinais positivos e negativos.

4.1.2 Modelo de médias móveis

Em um modelo de médias móveis, a combinação dos ruídos brancos e do período atual com aqueles passados origina a série. O modelo de médias móveis MA(q) é descrito por:

$$Z_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (3)$$

Onde: Z_t = série de dados históricos; θ_i = é o parâmetro que descreve como Z_t se relaciona os valores passados $\varepsilon_{t-1}, 1, 2, 3, \dots, q$; ε_t = ruído branco;

A representação mais simples desse modelo é o MA (1), apresentando período um ($q=1$):

$$Z_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (4)$$

Nesse modelo, a função de auto-correlação apresenta apenas a primeira auto-correlação não nula, e as demais todas nulas.

4.1.3 Modelo auto-regressivo de médias móveis

Quando há a necessidade de se utilizar grande número de parâmetros, os modelos AR(p) e MA(q) poder não apresentar bom desempenho. Com isso, é vantajoso aliar os dois modelos e seus parâmetros (p e q, respectivamente), compondo assim o modelo ARMA (p,q), que exigirá um número menor de parâmetros. Ele é representado pela seguinte equação:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (5)$$

A representação mais simples desse modelo é o ARMA (1,1) algebricamente dada por:

$$Z_t = \phi_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (6)$$

A auto-correlação do modelo ARMA (p,q), quando as defasagens (k) são menores que o período de memória (q), isso é ($k < q$), apresenta características MA (q) porque a memória desse componente dura apenas “q” períodos. Quando ($k > q+1$) as características são de um modelo AR (p).

4.2 Modelos não-estacionários

Quando uma série apresenta tendência e a variação dos dados não permanece constante, dizemos que ela é não estacionária, apresentando média e variância dependentes do tempo. Pode-se detectar esses padrões através de comparações de gráficos ou de alguns testes específicos.

4.2.1 Modelo auto-regressivo integrado de médias móveis

O método ARIMA consiste em transformar uma série não-estacionária em uma série estacionária, a fim de aplicar os métodos estatísticos de análise de séries. Um dos métodos de transformação mais comuns é citado por Ribeiro et al (2003) consiste em tomar diferenças sucessivas da série original até obter-se uma série estacionária. A primeira diferença de dados (Δz_t) e a segunda são dadas por:

$$\Delta z_t = Z_t - Z_{t-1} \quad (7)$$

$$D^2 z_t = Z_t - 2Z_{t-1} + Z_{t-2} \quad (8)$$

O número "d" de diferenças necessárias para tornar a série estacionária é denominado ordem de integração. Sua inclusão permite que seja utilizado o modelo ARIMA (p,d,q), descrito pela equação:

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (9)$$

Onde: $w_t = \Delta z_t$

4.3 Modelos Sazonais

Quando os dados são observados em períodos inferiores a um ano, a auto-correlação sucessiva, analisada no modelo ARIMA, pode apresentar padrões sazonais. Para analisar essas séries existe um modelo próprio. O Seasonal Auto Regressive Integrated Moving Averages (SARIMA). Ele possui uma parte não sazonal, oriunda do modelo ARIMA com parâmetros (p,d,q), e uma parte sazonal com parâmetros (P,D,Q)_s. Segundo Ribeiro et al (2003), o modelo mais geral é dado pela equação:

$$(1-\phi_1L-\dots-\phi_pL^p)(1-\Phi_1L^s-\dots-\Phi_PL^{Ps})(1-L)^d(1-L^s)^D Z_t=(1-\theta_1L-\dots-\theta_qL^q)(1-\Theta_1L^s-\dots-\Theta_QL^{Qs})\varepsilon_t \quad (10)$$

Onde: $(1-\phi_1L-\dots-\phi_pL^p)$ é a parte auto-regressiva não-sazonal de ordem p; $(1-\Phi_1L^s-\dots-\Phi_PL^{Ps})$ é a parte auto-regressiva sazonal de ordem P e estação sazonal s; $(1-L)^d$ é parte de integração não-sazonal de ordem d; $(1-L^s)^D$ é parte de integração sazonal de ordem D e estação sazonal s; $(1-\theta_1L-\dots-\theta_qL^q)$ é a parte não-sazonal de médias móveis de ordem q; $(1-\Theta_1L^s-\dots-\Theta_QL^{Qs})\varepsilon_t$ é a parte sazonal de médias móveis de ordem Q e estação sazonal s;

5.A aplicação da metodologia Box-Jenkins a previsão do preço da energia elétrica

Para a aplicação da metodologia Box-Jenkins foi utilizada uma série temporal com os valores de comercialização da energia elétrica (R\$/MWh). Esses dados foram obtidos junto a Câmara de Comercialização de Energia Elétrica (CCEE, 2008) e como eram cotados semanalmente, calculou-se uma média mensal para facilitar a análise dos dados e a aplicação dos modelos. São datados desde Julho de 2001 até Abril de 2008, porém, os dados referentes ao ano de 2001 até Junho de 2002 não foram considerados devido a sua conturbação, provocada pela crise energética brasileira ocorrida neste período e seus efeitos na sociedade como um todo, o chamado "apagão". A estruturação do modelo seria muito influenciada por esse evento isolado, já que não se trata de um problema constante e prejudicaria muito as previsões. Buscou-se dessa forma então, analisar dados que correspondessem o mais fielmente a realidade energética nacional.

Como a região sudeste/centro-oeste concentra a maior parte da população, sua série temporal de valores de energia foi escolhida para ser analisada neste trabalho. Caso os resultados esperados sejam atingidos, pode-se estender esse estudo para as demais regiões.

Outro ponto importante a ser destacado é o fato da diferenciação tarifária para as diferentes quantidades de carga demandada. Segundo Andrade & Ramalho (2002) existem três tipos de cargas: pesada, que demanda maior quantidade de carga (horários de pico); média, com uma demanda intermediária (entre às 06:00 e às 24:00h menos os picos); e leve, requerendo baixa quantidade de carga (entre às 00:00 às 06:00h). Porém a análise gráfica das três séries (Figura 1) mostrou que sua distribuição é praticamente a mesma. Sendo assim, toda a aplicação da metodologia Box-Jenkins será feita sobre os dados da série de preço da energia intermediária, correspondente ao maior período do dia.

Apenas os dados referentes ao período de Julho de 2002 a Junho de 2007 foram utilizados na configuração do modelo, deixando os dados restantes para realização de testes.

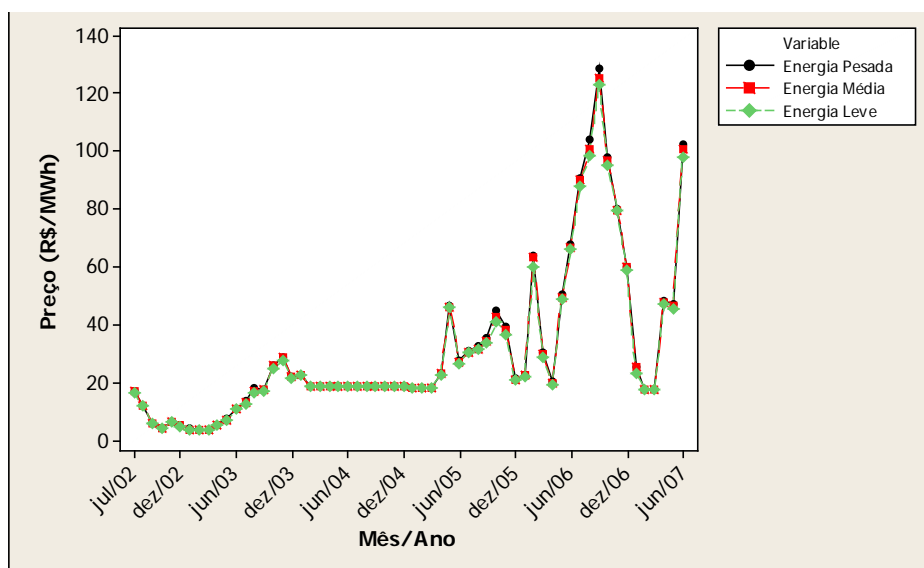


Figura 1: Distribuição do preço dos tipo energia ao longo do tempo na região SE/CO

5.1 Etapa de identificação

A análise do gráfico da distribuição de preço da energia ao longo do tempo auxilia a determinar quais modelos poderiam ser aplicados. A figura mostra que a série apresenta tendência (crescente), indicando sua não-estacionaridade, além da inconstante variabilidade dos valores.

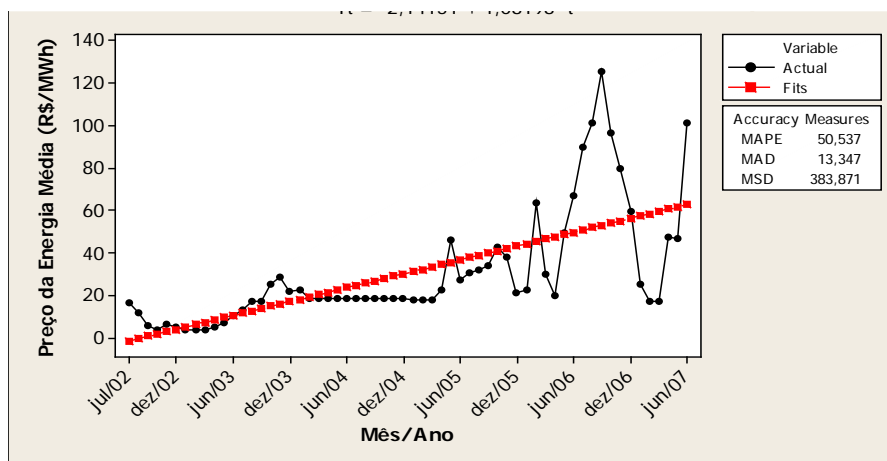


Figura 2: Gráfico da Análise de tendência série temporal de preço da energia Média

A análise das funções de auto-correlação (ACF) e auto-correlação parcial (PACF) ajudam na determinação dos parâmetros (p,d,q) do modelo ARIMA. A figura 3 apresenta a função de auto-correlação dos preços de energia. Percebe-se que ela decai exponencialmente, apresentando um típico comportamento auto-regressivo.

Segundo Souza (2006) o primeiro parâmetro a ser determinado é o grau de diferenciação "d" necessário à estabilização dos dados e isto é feito através da análise do

diagrama da função de auto-correlação (ACF). Se ele decrescer de forma exponencial, realizam-se diferenciações na série, até que o diagrama apresente um corte abrupto para um valor qualquer de auto-correlação, quando a série será considerada estacionária.

Analisando-se a figura 3 percebe-se que a função de auto-correlação não está em equilíbrio. Com isso, é necessário realizar diferenciações a fim de estabilizar a série.

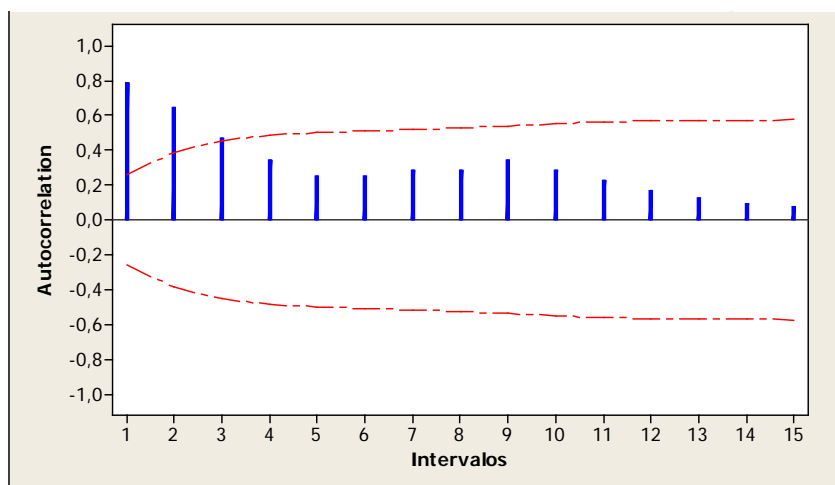


Figura 3: Função de auto-correlação para preço de energia média

A figura 4 apresenta a função de auto-correlação para a primeira diferenciação. Percebe-se que desta vez o diagrama apresenta mudanças repentinas de valores, então pode-se considerar que a série está em equilíbrio e que o parâmetro de diferenciação "d" é igual a um ($d=1$), e, como para se obter a estacionariedade da série foi preciso utilizar diferenciação, pode-se adotar que o parâmetro de memória da média móvel "q" é zero ($q=0$) (Ribeiro et al, 2003).




Figura 4: Função de Auto-correlação para a 1ª diferenciação

A figura 5, por sua vez, apresenta a função de auto-correlação parcial dos preços e, neste caso, pode-se perceber após o primeiro intervalo que a função sofre um grande queda. Assim, o parâmetro de auto-regressão "p" possui valor um ($p=1$).

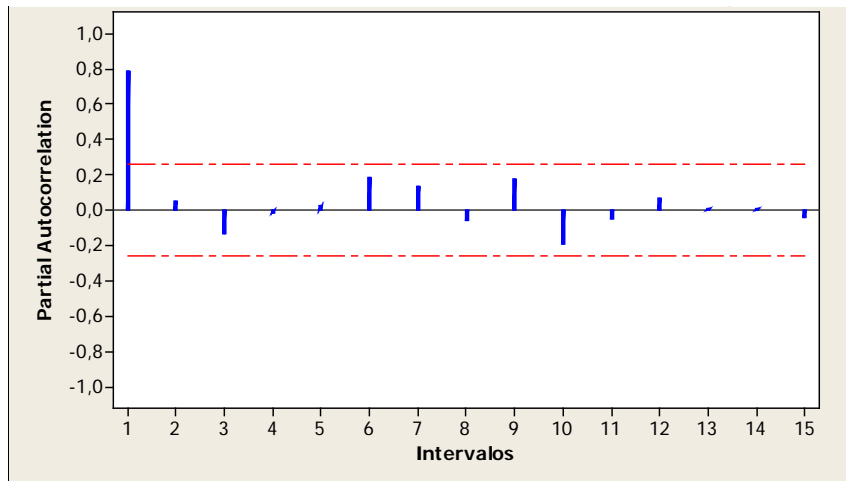


Figura 5: Função de Auto-correlação parcial para o preço da energia média

Após a análise das funções de auto-correlação e auto-correlação parcial, o modelo estimado foi o ARIMA (1,1,0).

5.2 Etapa de Estimativa

A etapa de estimativa consiste em estimar os valores dos parâmetros da equação (10) sendo feita, normalmente, através de softwares. Esses dados não serão apresentados neste trabalho já que a formulação matemática não será utilizada na prática. As previsões serão realizadas com o auxílio da ferramenta computacional MINITAB versão 15.

5.3 Etapa de Verificação

A verificação é feita através da análise dos gráficos da ACF e PACF (figura 6) dos resíduos onde se verifica se estes se comportam como ruídos brancos, apresentando auto-correlação insignificante. A análise da figura 6 permite perceber dados significantes. Segundo Ribeiro et al (2003) isso indica a presença de sazonalidade.




Figura 6: Gráficos das funções de auto-correlação e auto-correlação parcial dos resíduos ARIMA(1,1,0)

Foram propostos então, uma série de modelo SARIMA (p,d,q)(P,D,Q), com passo sazonal doze ($s=12$), já que tratam-se de períodos anuais compostos por 12 meses, e o modelo SARIMA (1,0,1)(1,2,1) apresentou o melhor comportamento. A análise dos gráficos da ACF e PACF (figura 7) deste modelo mostraram que os resíduos comportaram-se como ruídos brancos.




Figura 7: Gráficos das funções de auto-correlação e auto-correlação parcial dos resíduos SARIMA(1,0,1)(1,2,1)₁₂

5.4 Etapa de Previsão

Com o auxílio do software MINITAB 15 realizou-se a previsão dos preços para o período entre Novembro de 2005 e Junho de 2007, dados que foram utilizados na construção do modelo. Tal procedimento foi realizado para verificar como as previsões acompanhavam a série. Também se realizou a previsão dos preços entre o Julho de 2007 a Abril de 2008. A figura 8 mostra a disposição desses dados ao longo do tempo, incluindo os limites de 95%, inferiores e superiores das previsões.




Figura 8: Gráfico da série de tempo do preço da energia, das previsões e seus limites inferior e superior (95%)

Devido ao pequeno número de dados, não foi possível verificar todos os valores passados da série, por uma questão de convergência no processo iterativo de análise dos dados. Porém pode-se perceber que no período no qual foi aplicado o processo de previsão, os dados obtidos apresentam razoável proximidade com os dados reais.

6. Conclusão

Conseguir prever com antecedência o custo da energia elétrica é um processo muito importante e, ao mesmo tempo, extremamente complexo. Obter aproximações dos futuros valores de comercialização desse bem possibilita que o mercado se posicione melhor quanto a suas flutuações orientando-se em suas decisões. Tais ações oferecem uma maior segurança aos investidores e também aos consumidores.

Com tal objetivo, este trabalho empregou uma das mais clássicas técnicas de previsão, a metodologia Box-Jenkins, na análise da série temporal de preços de energia.

A região sudeste/centro-oeste foi definida como alvo do estudo, visto que, em virtude do extenso território brasileiro, o mercado nacional de energia é segmentado em quatro regiões nas quais a cotação de preços varia. Também foi escolhida a série de valores referente à energia média, despendida durante o maior período do dia. Foram cotados valores médios mensais para facilitar a aplicação das técnicas.

Após a análise da série temporal constatou-se a presença de uma tendência de crescimento do preço da energia. Tal fenômeno pode ser explicado pelo aumento da demanda,

devido ao crescimento econômico do país nos últimos anos, e a falta de investimentos no setor, não permitindo que este se expandisse.

A análise das funções de auto-correlação (ACF) e auto-correlação parcial (PACF), da série e das diferenças, permitiu determinar o modelo ARIMA (1,1,0) como o adequado para descrever a série. Porém, a análise das funções ACF e PACF dos resíduos do modelo encontrado apontaram a presença de sazonalidade. Tal constatação é bastante plausível visto que, a demanda de energia influencia no seu preço e esta varia ao longo do ano conforme as estações climáticas. Outro fator de influencia sazonal direta no preço da energia é a quantidade de chuvas durante o período. Ele controla o nível de água das usinas, base da geração da energia nacional, e determina sua capacidade produtiva.

Com base nessa análise, foram propostos uma série de modelos sazonais SARIMA (1,0,1)(1,2,1)₁₂ e a verificação da ACF e da PACF dos seus resíduos demonstrou que este modelo era adequado para descrever a série de preços de energia.

A análise dos dados da série de previsão mostrou que o modelo é válido já que conseguiu estimar valores próximos aos reais com exceção do período entre Outubro de 2007 e Março de 2008 (Tabela 1). Pode-se justificar tal defasagem pelo fato deste período corresponder a um dos mais longos períodos de estiagem da história em varias regiões do país, constituindo-se um evento isolado que causou certo desequilíbrio no mercado de energia. Quando o mercado se reestabilizou, a previsão foi precisa (dado referente à primeira semana de Maio de 2008).

Período Referente	Valor Real(Vr)	Valor Previsto(Vp)	Diferença(Vr-Vp)
jul/07	132,16	111,99	20,17
ago/07	41,82	114,17	-72,35
set/07	148,08	131,01	17,07
out/07	189,01	111,11	77,90
nov/07	192,61	89,95	102,66
dez/07	200,42	58,14	142,29
jan/08	464,87	30,49	434,38
fev/08	261,91	58,56	203,35
mar/08	130,19	27,37	102,82
abr/08	68,80	38,07	30,73
mai/08	41,33	51,75	-10,42

Fonte: Microsoft Excel 2003

Tabela 1: Diferença entre o valor real observado e o valor previsto pelo modelo SARIMA(1,0,1)(1,2,1)

A aplicação de outros métodos de previsão ou da metodologia Box-Jenkins, separadamente, nos fatores que influenciam o preço da energia, como: demanda e quantidade de chuva, entre outros; e a determinação de uma função de relação entre eles poderia possibilitar uma previsão mais eficaz.

7. Agradecimentos

Os autores agradecem a Fundação de Apoio a Pesquisa de Minas Gerais (FAPEMIG) pelo suporte fornecido durante todo desenvolvimento do trabalho.

8. Bibliografia

- Anderson, O.;** *Time series analysis and forecasting: the Box-Jenkins approach.* London; Boston : Butterworth, 1976.
- Andrade, M.; Ramalho, E.;** *O mercado brasileiro de energia elétrica: lições e perspectivas decorrentes do racionamento.* AGRENER – 4o. Encontro de Energia o Meio Rural. 2002
- Brum, M.; Fogliatto, F.; Ribeiro, J; Werner, L.; Lemos, F.;** *Previsão de demanda por energia elétrica – Método e aplicação.* XXV Encontro Nac. de Eng. de Produção – Porto Alegre, RS, Brasil, 29 out a 01 de nov de 2005
- CCEE,** Câmara de Comercialização de Energia Elétrica; site: www.ccee.org.br; 2008.
- Davinson, M.; Anderson, C.L.; Marcus, B. and Anderson, K.;** *Development of a Hybrid Model for Electrical Power Spot Prices.* IEEE Transaction on Power Systems, vol. 17, no.2, 2002.
- Fávero, L.; Oliveira, M.;** *Uma breve descrição de algumas técnicas para análise de séries temporais: Séries de Fourier, Wavelets, ARIMA, Modelos estruturais para séries de tempo e redes neurais.* VI SEMEAD 2002.
- Garcia, C.; Contreras, J.; Akkeren, M. and Garcia, J.;** *A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices,* IEEE Transaction on Power Systems, vol. 20, no. 2, May 2005.
- González, M.; San Roque, M. and González, J. ;** *Modeling and Forecasting Electricity Prices with Input/Output Hidden Markov Models,* IEEE Transaction on Power Systems, vol. 20, no. 1 ,2002.
- Longo, R.; Bermann, C.;** *Avaliação do processo de reestruturação do setor elétrico brasileiro: das propostas à realidade.* Revista FAAP engenharia ano 16 edição 43, 2003.
- Medeiros, L.;** *Previsão do preço spot no mercado de energia elétrica,* 144p.Tese de Doutorado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, PUC-Rio. Rio de Janeiro, 2003.
- MINITAB** version 15; Products installed: Minitab® 15.1.0.0.; © 2006 Minitab Inc. All rights reserved.
- Moricochi, L.; Pino, F.; Vegro, C.;** *Método DELPHI como alternativa para previsões de safras: o exemplo do café.* Informações Econômicas, SP, v.25, n.12, dez. 1995.
- Niimura, T.;** *Forecasting Techniques for Deregulated Electricity Market Prices,* IEEE, 2006.
- Ribeiro, J.; Werner, L.;** *Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.* Gestão e. Produção. vol.10 no.1 São Carlos Apr.2003.

Souza, B.; *Previsão de demanda utilizando métodos estatísticos – um estudo sobre os modelos ARIMA de Box-Jenkins.* Projeto Final de Graduação, Instituto de Engenharia de Produção e Gestão – IEPG, Universidade Federal de Itajubá – UNIFEI. 2006.

Zan , L.; Sellito, A.; *Técnicas de previsão de demanda: um estudo de caso triplo com dados de venda de materiais eletro-mecânicos.* GEPROS. Gestão de Produção, Operações e sistemas- Ano 2, vol. 4, jul-set, p. 95-106, 2007.