

UTILIZAÇÃO DO MÉTODO DE BOX-JENKINS PARA MODELAGEM E PREVISÃO DA PRODUÇÃO BRASILEIRA DE AUTOVEÍCULOS

Jair Paulino de Sales¹
João Marcos Pereira Silva²
Viviane Gonçalves Dias³
Paulo Renato Alves Firmino⁴

Resumo

A indústria automobilística desempenha papel fundamental para o desenvolvimento de um país devido a sua capacidade agregadora. A influência exercida pelas indústrias japonesas ao mercado internacional obrigou o mercado ocidental a delimitar um processo de reestruturação que incluísse a utilização de novas práticas gerenciais, sobretudo aquelas focadas no desenvolvimento de técnicas de auxílio ao planejamento e à tomada de decisões. O presente estudo utilizou o formalismo de Box-Jenkins para a modelagem e previsão da produção brasileira de autoveículos, a partir de dados da ANFAVEA. O modelo SARIMA (2,2,1)(2,2,1)₁₂ apresentou melhor desempenho dentre todos os testados, sugerindo uma relação temporal da produção mensal destes veículos com seus índices dos seis,

Recebimento: 22/5/2017 - Aceite: 5/6/2018

1 Engenheiro de Produção (URCA), mestrando em Desenvolvimento Regional Sustentável (PRODER/UFCA). E-mail: jairpsales@hotmail.com

2 Engenheiro de Produção (URCA), mestrando em Engenharia de Produção (PPGEP/UFPB). E-mail: joaomarkco@gmail.com

3 Graduanda em Engenharia Civil (UFCA), bolsista de Iniciação Científica (CNPQ/UFCA). E-mail: joaomarkco@gmail.com

4 Estatístico (UFPE), mestre e doutor em Engenharia de Produção (PPGEP/UFPE). Professor da Universidade Federal do Cariri. E-mail: paulo.firmino@ufca.edu.br

doze e vinte e quatro meses regressos. Contatou-se uma tendência negativa na produção brasileira de autoveículos para o período analisado, o que condiz com a atual conjuntura do país.

Palavras-chave: Setor automobilístico. Séries temporais. Box-Jenkins. SARIMA.

USE OF THE BOX AND JENKINS' METHOD FOR MODELLING AND FORECASTING BRAZILIAN AUTOVEHICLE PRODUCTION

Abstract

The automotive industry plays a key role in the development of a country due to its aggregating capacity. The influence exerted by the Japanese industries to the international market has forced the western market to draw up a restructuring process that included the use of new management practices, particularly those focused on development aid techniques for decision-making. This study used the Box-Jenkins' method for modelling and forecasting the Brazilian production of vehicles, based on data from ANFAVEA. The SARIMA model $(2,2,1)(2,2,1)_{12}$ showed the best performance among all tested, suggesting a temporal relationship between the actual level of production and the previous six, twelve, and twenty four months. A negative trend was found in the Brazilian production of vehicles for the analyzed period, which is consistent with the current situation of the country.

Keywords: Automotive industry. Time series. Box-Jenkins. SARIMA.

Introdução

A importância da indústria automobilística para o desenvolvimento de um país surge a partir da capacidade agregadora desta, já que para a produção de um automóvel faz-se necessário, além do seu processo de desenvolvimento e de produção, um conjunto de produtos oriundo de outras empresas, como fabricantes de pneus, vidros, amortecedores, eletrônicos e demais componentes (GUARNIERI et al., 2009).

Entre os anos de 1950 e 1970 a indústria automobilística brasileira passou por uma fase de expansão acelerada subsidiada pelo presidente Kubitschek (ALMEIDA, 1972) e logo após por um período de declínio até meados de 1990, quando começou a sofrer influências positivas provenientes da nova política de abertura econômica brasileira, da baixa competitividade das indústrias nacionais e do processo de saturação do mercado automobilístico nos países desenvolvidos (FLIGENSPAN; CALANDRO, 2002; VANALLE; SALES, 2011).

O significativo aumento da influência exercida pelas indústrias automobilísticas japonesas ao mercado internacional no final do século XX obrigou as empresas do ocidente a delimitarem um processo de reestruturação que incluísse a utilização da automação e das práticas nipônicas (FLIGENSPAN; CALANDRO, 2002).

Entre os anos de 1995 e 1998, a política setorial denominada Regime Automotivo Brasileiro (RAB) deu suporte ao avanço da produção automobilística nacional ocasionando, neste período, um investimento quatro vezes maior do que a média estipulada para a década de 1980. A produção continuou a crescer até o ano de 2005, sofrendo uma desaceleração entre os anos de 2001 e 2003 (ALMEIDA, 2006), período no qual a venda de veículos de pequeno porte respondia por mais de 70% das vendas de automóveis no país (CONSON; CARVALHO, 2002). A produção nacional continuou seu crescimento até 2014, sofrendo duas grandes crises nos anos de 2008 e 2015.

Atualmente, quase todas as montadoras mundiais de grande porte possuem sede no Brasil, sendo o sudeste e o sul os maiores polos automobilístico do país (VANALLE; SALES, 2011). Entre os fatores de atratividade exercidos por estas regiões destacam-se a política de incentivos fiscais e a oferta de mão de obra qualificada (SESSO FILHO, 2004).

Por exercer um papel de indicador de desenvolvimento nacional, a indústria de automóveis é objeto de inúmeras pesquisas voltadas desde para as técnicas de desenvolvimento e produção quanto para processo de auxílio a tomada de decisões. Entre os estudos sobre tal temática, Walter et al. (2010) analisaram a utilização de técnicas de modelagem e previsão da

produção e venda de automóveis utilizando a metodologia Box-Jenkins e Guarneri et al. (2009) avaliaram o impacto da crise no setor automobilístico brasileiro no segundo semestre de 2008 fazendo uso destes modelos. Diante do exposto, o presente estudo objetiva a utilização da metodologia Box-Jenkins para a previsão da produção automobilística brasileira.

Séries temporais e o método de Box - Jenkins

Uma série temporal (ou série histórica/cronológica) constitui-se por um conjunto de observações registradas de forma ordenada em intervalos de instantes sucessivos (MORETTIN; TOLOI, 2006). O objetivo primário da análise de séries temporais é estudar o comportamento passado das variáveis envolvidas, visando o entendimento do seu comportamento e, desta forma, possibilitando previsões sob o menor erro possível (FONSECA; MARTINS; TOLEDO, 1985). Para uma boa análise, faz-se necessário o entendimento do comportamento de uma série temporal, motivo da importância da utilização de ferramentas gráficas, que facilitam o estabelecimento dos seus componentes (tendência, sazonalidade, variações cíclicas ou aleatórias) (SHAFER; MEREDITH, 1998). Uma série temporal é definida por Z_t , sendo $t = \{1, 2, \dots, n\}$. No presente trabalho, Z_t representa a quantidade de autoveículos produzidos no Brasil no mês t , de acordo com os registros da ANFAVEA.

O grupo de modelos ARIMA (*Auto regressive Integrated Moving Average*) foi proposto inicialmente por [George Boxe Gwilym Jenkins](#) na década de 1970 (BOX; JENKINS, 1970). Utiliza-se a notação ARIMA (p, d, q), sendo p , d e q , respectivamente, o número de parâmetros autorregressivos (AR), o número necessário de diferenciações (I) para que a série torne-se estacionária e número de parâmetros referentes às médias móveis (MA) (BAYER, 2008). Os componentes AR modelam as relações entre o valor atual da série e seus valores passados, enquanto que os componentes MA modelam a associação deste valor atual com o desempenho regresso do próprio modelo, medido através dos seus resíduos.

Guarnieriet al. (2009) definem um modelo puramente autorregressivo (AR), ou ARIMA ($p, 0, 0$), como:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (01)$$

Na qual Z_{t-p} ($i=1, \dots, p$) são seus valores passados autorregredidos e ε_t o erro aleatório e independente cuja modelagem é impossível. Utilizando-se o fator de defasagem L , dado por $L^n Z_t = Z_{t-n}$, pode-se reescrever a Equação (02) como:

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) = \phi(L) Z_t = \varepsilon_t \quad (02)$$

Os modelos de médias móveis (MA), ARIMA (0, 0, q), objetivam explicar a série a partir de q defasagens dos resíduos oriundos de um dado modelo (AVANCINI, 2015). Um modelo MA(q) é dado por (GUARNIERI et al., 2009):

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (03)$$

Na qual μ é a média de Z_t . Utilizando-se o fator de defasagem L, a Equação 03 transforma-se em:

$$(1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t = \theta(L) \varepsilon_t = Z_t \quad (04)$$

A união entre os modelos AR (p) e MA (q) origina o modelo ARMA (p,q), ou ARIMA (p,0,q), dado pela Equação 05, podendo ser reescrito nas Equações 06 e 07 a partir da utilização do fator de defasagem L:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (05)$$

$$(1 - \phi_1 L - \dots - \phi_p L^p) Z_t = (1 - \theta_1 L - \dots - \theta_q L^q) \varepsilon_t \quad (06)$$

$$\phi(L) Z_t = \theta(L) \varepsilon_t \quad (07)$$

Segundo Guarnieriet al. (2009), um modelo ARMA(p,q) possui as mesmas condições de estacionaridade de um modelo AR(p) e invertibilidade de um modelo MA(q). Entretanto, a utilização de modelos ARMA restringe-se a séries temporais estacionárias. Como a maioria das séries reais são não estacionárias, faz-se necessária uma metodologia de estacionarização destas. Amaral (2014) afirma que uma série Z_t não estacionária pode ser convertida em uma série W_t estacionária através de d diferenciações, de acordo com a Equação 08.

$$W_t = \Delta^d Z_t = (1 - L)^d Z_t \quad (08)$$

Logo, a partir da realização de diferenciações, o modelo ARIMA (p, d, q) pode ser descrito como:

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (09)$$

Utilizando o fator de defasagem L obtêm-se as equações 10 e 11.

$$(1 - \phi_1 L - \dots - \phi_p L^p)(1 - L)^d Z_t = (1 - \theta_1 L - \dots - \theta_q L^q) \varepsilon_t \quad (10)$$

$$\phi(L) \Delta^d Z_t = \theta(L) \varepsilon_t \quad (11)$$

Assim como o ARIMA acrescenta o fator de estacionarização ao ARMA, o SARIMA incrementa o ARIMA por meio do fator de sazonalidade. O modelo pode ser descrito como SARIMA (p, d, q)(P, D, Q)_s, sendo s o fator de sazonalidade, p, d e q as ordens do modelo ARIMA e P, D e Q as ordens do modelo sazonal (GUARNIERI et al., 2009), segundo Equação 12.

$$(1 - \phi_1 L - \dots - \phi_p L^p)(1 - \phi_1 L^s - \dots - \phi_p L^{ps})(1 - L)^d (1 - L^s)^D Z_t = (12)$$

$$(1 - \theta_1 L - \dots - \theta_q L^q)(1 - \theta_1 L^s - \dots - \theta_q L^{qs}) \varepsilon_t$$

Na qual (WERNER; RIBEIRO, 2003):

$(1 - \phi_1 L - \dots - \phi_p L^p)$ = parcela autoregressiva e não-sazonal de ordem p ;

$(1 - \phi_1 L^S - \dots - \phi_p L^{pS})$ = parcela autoregressiva e sazonal de ordem P e fator de sazonalidade S ;

$(1 - L)^d$ = parcela de integração sazonal de ordem d ;

$(1 - L^S)^D$ = parcela de integração sazonal de ordem D e fator de sazonalidade S ;

$(1 - \theta_1 L - \dots - \theta_q L^q)$ = parcela de médias móveis não-sazonal;

$(1 - \theta_1 L - \dots - \theta_q L^{qS})$ = parcela de médias móveis não-sazonal e fator de sazonalidade S .

Considerando que os modelos propostos são falíveis e susceptíveis ao erro ao estimarem as séries reais correspondentes e que mais de um modelo pode descrever uma mesma série, faz-se necessária a utilização de critérios de comparação entre os modelos propostos para que se possa realizar previsões com menores erros (TEODORO, 2015). Entre as ferramentas mais utilizadas para a realização dos testes de avaliação de qualidade, destacam-se os critérios de informação de Akaike (AIC), Bayesiano (BIC) e de Hannan Quinn (HQC) (FURLAN, 2009) (Eqs. 13-15). Os critérios AIC e BIC baseiam-se no máximo da função de verossimilhança, fixados os valores da série e dos parâmetros do modelo, enquanto o HQC é uma alternativa aos dois primeiros.

$$\begin{aligned} AIC &= -2 \log(\text{máxima verossimilhança}) + 2k & (13) \\ BIC &= -2 \log(\text{máxima verossimilhança}) + \ln(n_{par})k & (14) \\ HQC &= -2 \log(\text{máxima verossimilhança}) + 2k \ln(\ln(n_{par})) \end{aligned}$$

Onde k representa o número de parâmetros nos modelos e n_{par} o tamanho da amostra.

Materiais e métodos

Para o presente estudo utilizou-se uma série temporal construída a partir de dados da Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA) referentes à produção mensal de autoveículos (automóveis, comerciais leves, caminhões e ônibus) no Brasil entre janeiro de 2005 e junho de 2015, totalizando 126 observações. A série foi analisada descritivamente para determinação de componentes cíclicos e sazonais. Utilizaram-se as funções de autocorrelação (FAC) e autocorrelação parcial

(FACP) e o teste de Dickey-Fuller Aumentado para determinação da estacionaridade da série.

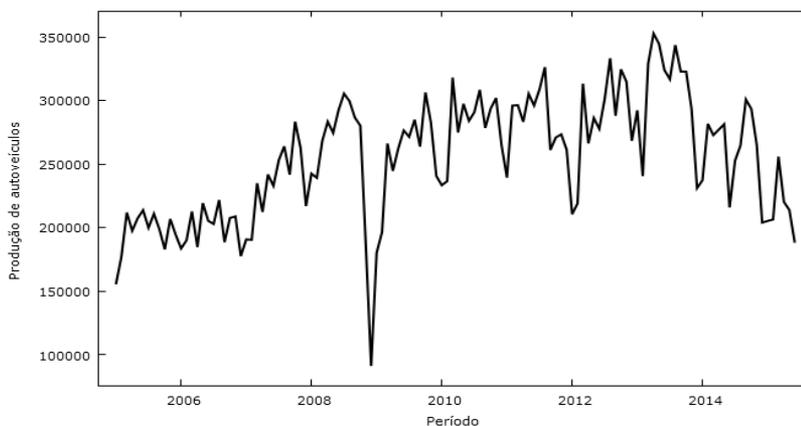
O estudo desenvolveu-se segundo a metodologia Box-Jenkins descrita por Murteira, Muller e Turkman (1993), contemplando: a) Identificação do problema e escolha do modelo; b) estimação dos parâmetros do modelo; c) avaliação do diagnóstico de qualidade; d) realização da previsão.

Para a avaliação do diagnóstico de qualidade utilizaram-se os critérios de informação de Akaike, Bayesiano e de Hannan Quinn. Para modelagem dos dados estatísticos utilizaram-se os *software Microsoft Excel 2010* e *Gretl 1.10.2* (GRETL TEAM, 2017).

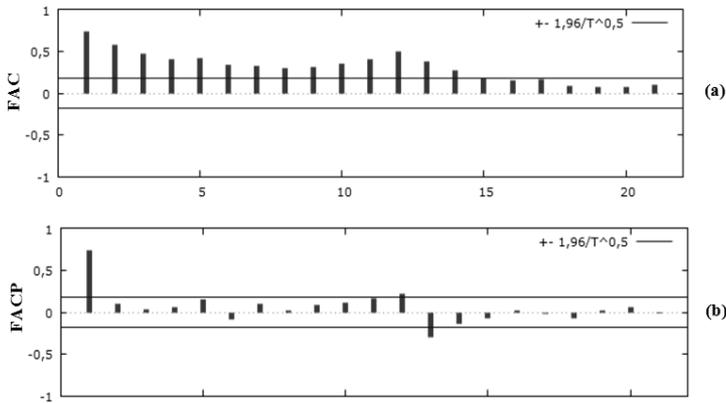
Resultados e discussão

Verificou-se a estacionaridade da série a partir do gráfico da produção de autoveículos no Brasil no período compreendido entre janeiro de 2005 e junho de 2015 (Figura 01), do seu correlograma (Figura 02) e do teste de Dickey-Fuller Aumentado, confirmando que a mesma é não estacionária.

Figura 1: Produção de autoveículos no Brasil entre janeiro de 2005 e julho de 2015, de acordo com a ANFAVEA.

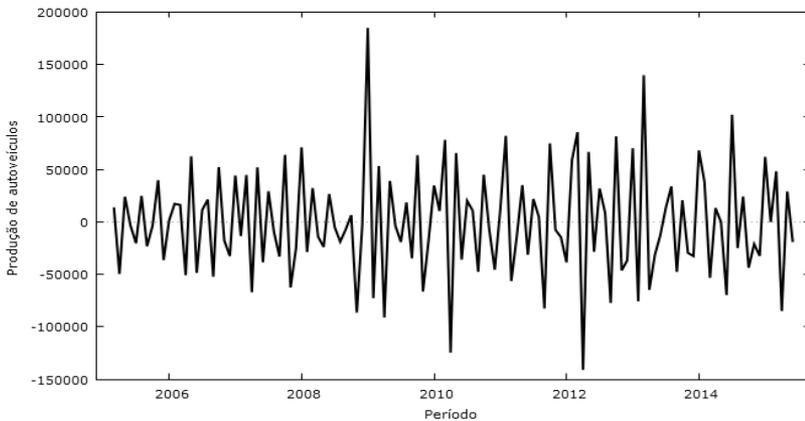


Fonte: Autores (2016)

Figura 2: FAC (a) e FACP (b) da produção de autoveículos no Brasil.

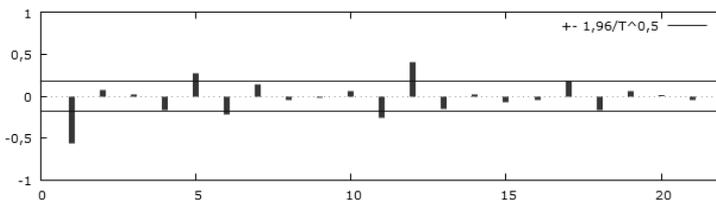
Fonte: Autores (2016)

Com o intuito de transformar a série em estacionária, diferenciou-se a mesma uma vez. Após realização de todos os testes confirmou-se novamente a não estacionariedade. A série foi novamente diferenciada confirmando-se a estacionariedade, como indicam as Figuras 03 e 04.

Figura 3: Série da produção de autoveículos no Brasil diferenciada duas vezes.

Fonte: Autores (2016)

Figura 4: FAC da segunda diferenciação da produção de autoveículos no Brasil.



Fonte: Autores (2016)

O modelo a ser adotado utilizará então $d = 2$, já que foram necessárias duas diferenciações para que a série em estudo se tornasse estacionária. Para a estimação dos parâmetros $AR(p)$ e $MA(q)$ foram analisadas as funções FAC e FACP. A presença de autocorrelações parciais significativas nos lags 1 e 13 na FACP (Figura 02 b) indica possível presença de sazonalidade $s = 12$. Desta forma, a fim de eliminar a influencia da componente sazonal, optou-se pela utilização da diferença sazonal. Foram necessárias duas diferenças sazonais para que a série se apresentasse sem componente sazonal, logo $D = 2$. Para a estimação dos parâmetros $AR(P)$ e $MA(Q)$ foram analisadas as funções FAP e FAPC da segunda diferença sazonal da série em estudo.

Seguindo metodologia Morettin e Tolo (2004), mais de um modelo foi proposto, para que, a partir de ferramentas de comparação, pudesse ser escolhido o melhor. Os modelos propostos estão apresentados na Tabela 01, isto é, o $ARIMA(2,2,1)(2,2,1)_{12}$ considerando AIC e HQC e o $ARIMA(2,2,1)(1,2,1)_{12}$ via BIC.

Tabela 1: Modelos e critérios de comparação para a produção de autoveículos no Brasil (*software*Gretl 1.10.2). Os melhores valores dos critérios encontram-se em **negrito**.

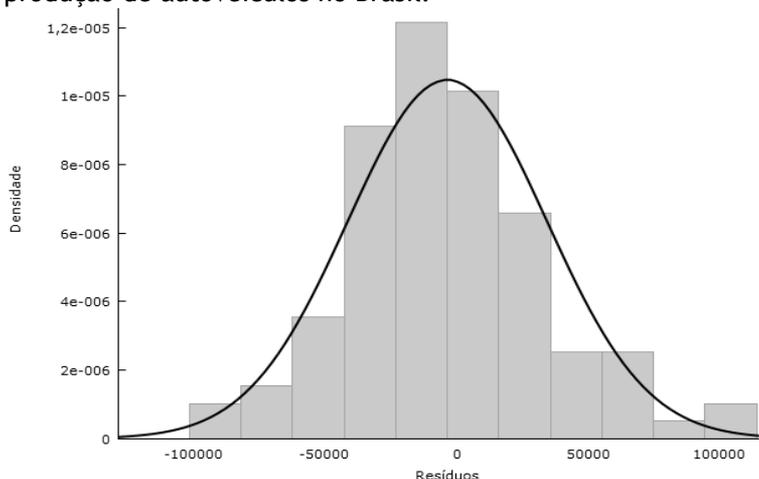
Modelo	Coefficientes	p-value dos coeficientes	AIC	BIC	HQC
ARIMA (2,2,1)(2,2,1) ₁₂	$\theta_1 = -0,334823$ $\theta_2 = -0,222877$ $\theta_1 = -1,00000$ $\phi_1 = -0,417123$ $\phi_2 = -0,233997$ $\theta_1 = -1,00000$	< 0,0008 < 0,0248 < 0,0000 < 0,0304 < 0,0000 < 0,0000	2408,3	2426,5	2415,7
ARIMA (2,2,1)(1,2,1) ₁₂	$\theta_1 = -0,375442$ $\theta_2 = -0,204264$ $\theta_1 = -1,00000$ $\phi_1 = -0,301172$ $\theta_1 = -0,999992$	< 0,0001 < 0,0386 < 0,0018 < 0,0000 < 0,0000	2410,5	2426,2	2416,9
ARIMA (2,1,0)(1,2,1) ₁₂	$\theta_1 = -0,380520$ $\theta_2 = -0,209422$ $\phi_1 = -0,303922$ $\theta_1 = -1,00000$	< 0,0000 < 0,0320 < 0,0015 < 0,0000	2423,3	2436,4	2428,6
ARIMA (2,1,0)(2,2,1) ₁₂	$\theta_1 = -0,338477$ $\theta_2 = -0,229118$ $\phi_1 = -0,423137$ $\phi_2 = -0,242248$ $\theta_1 = -0,999997$	< 0,0007 < 0,0197 < 0,0000 < 0,0236 < 0,0000	2420,7	2436,4	2427,1
ARIMA (2,1,1)(1,2,2) ₁₂	$\theta_1 = -1,14652$ $\theta_2 = -0,370182$ $\theta_1 = 0,865163$ $\phi_1 = 0,296530$ $\theta_1 = -1,93409$ $\theta_2 = 1,00000$	< 0,0000 < 0,0000 < 0,0567 < 0,0000 < 0,0000 < 0,0006	2418,2	2436,5	2425,6
ARIMA (2,1,1)(1,2,0) ₁₂	$\theta_1 = -1,27398$ $\theta_2 = -0,3433308$ $\theta_1 = 1,00000$ $\phi_1 = -0,574570$	< 0,0000 < 0,0000 < 0,0000 < 0,0000	2456,3	2469,4	2461,6

Foram propostos, então, seis modelos, entre os quais o número de coeficientes variou de 4 a 6. Os três critérios analisados apresentaram, em votação, o modelo ARIMA (2,2,1)(2,2,1)₁₂ como detentor de melhores índices, logo este será utilizado para a realização da previsão. Através do histograma (Figura 05) e da função de autocorrelação dos resíduos (Figura 06) verificou-se a distribuição normal do modelo selecionado. De acordo

com a Equação 12 demonstrada no início deste trabalho o modelo SARIMA $(2,2,1)(2,2,1)_{12}$ pode ser assim descrito:

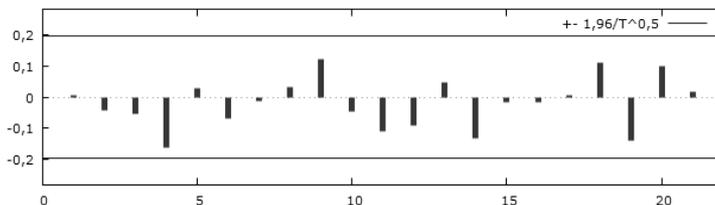
$$\frac{(1 + 0,335L + 0,223L^2)(1 + 0,417L^{12} + 0,234L^{24})(1 - L)^2(1 - L^{12})^2 Z_t}{(1 + L)(1 + L^{12})} = \varepsilon_t(16)$$

Figura 5: Distribuição normal dos resíduos do modelo ARIMA $(2,2,1)(2,2,1)_{12}$ para a produção de autoveículos no Brasil.



Fonte: Autores (2016)

Figura 6: FAC dos resíduos do modelo ARIMA $(2,2,1)(2,2,1)_{12}$ para a produção de autoveículos no Brasil.



Fonte: Autores (2016)

A Tabela 02 apresenta os valores reais da produção de autoveículos no Brasil no primeiro semestre de 2015 e os valores previstos para o todo o ano de 2015.

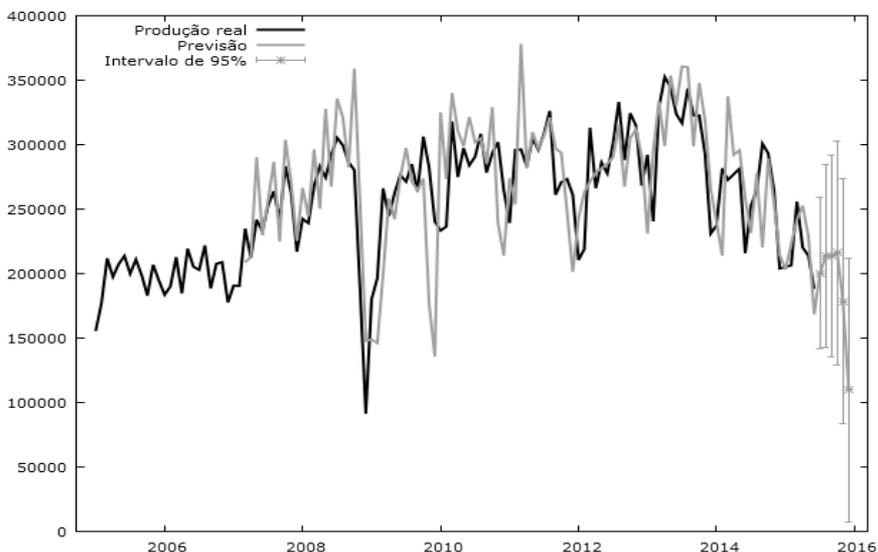
Tabela 2: Produção real e previsão para o ano de 2015 do modelo ARIMA (2,2,1)(2,2,1)₁₂ para a produção de autoveículos no Brasil.

Período	Valor real	Valor previsto	Intervalo	
			Inferior (95%)	Superior (95%)
Jan - 2015	205.305	203.226	-	-
Fev - 2015	206.450	222.738	-	-
Mar - 2015	255.866	241.941	-	-
Abr - 2015	220.322	252.754	-	-
Mai - 2015	213.853	228.387	-	-
Jun - 2015	188.195	168.452	-	-
Jul - 2015	-	200.348	141.538	259.159
Ago - 2015	-	213.792	143.159	284.425
Set - 2015	-	213.715	135.921	291.510
Out - 2015	-	215.964	128.862	303.066
Nov - 2015	-	178.632	83.430	273.834
Dez - 2015	-	109.910	7.694	212.127

A Figura 07 apresenta o gráfico da produção entre janeiro de 2005 e junho de 2015 e a previsão entre janeiro de 2007 e dezembro de 2015. A crise automobilística de 2008 é facilmente identificada na Figura 07, o valor referente à produção automobilística em dezembro daquele ano foi a menor desde dezembro de 1999.

É possível perceber um comportamento cíclico da série, já que apresenta valores em decréscimo nos meses de novembro e dezembro, voltando a crescer nos meses de março e abril. Em relação ao segundo semestre de 2015, a previsão identificou queda brusca na produção de autoveículos.

Figura 7: Produção real e prevista do modelo ARIMA (2,2,1)(2,2,1)₁₂ para a produção de autoveículos no Brasil.



Fonte: Autores (2016)

Considerações finais

A utilização de técnicas de previsão a partir de séries temporais univariadas se mostra como ferramenta útil em processos de tomada de decisões em geral e ao setor automobilístico em especial. Para a realização de previsões, podem ser empregadas inúmeras técnicas qualiquantitativas ou puramente quantitativas. Neste estudo optou-se pela utilização de modelos SARIMA, propostos por Box-Jenkins, a partir de um estudo hipotético-dedutivo envolvendo seis estruturas de modelagem.

Após identificação do problema, escolha do modelo, estimação dos seus parâmetros e avaliação de seus resíduos concluiu-se que o SARIMA (2,2,1)(2,2,1)₁₂ apresentou melhor desempenho entre todos os modelos testados. Com a realização da previsão para o segundo semestre de 2015, constatou-se uma tendência negativa na produção brasileira de autoveículos, o que condiz com a atual conjuntura do país. Constatou-se ainda que os valores previstos para dezembro de 2015 assemelham-se aos valores reais de dezembro de 2008, ano marcado por grave crise no setor imobiliário, indicando urgência em atividades que possam retardar os efeitos da atual crise.

Com proposta de trabalhos futuros, encoraja-se a utilização de outras técnicas de previsão como os modelos multiplicativos e aditivos de

Holt-Winters e redes neurais para comparação com os resultados aqui descritos. O uso de combinadores de modelos de previsão tem sido também investigado.

Referências

ALMEIDA, C. C. R. et al. Indústria automobilística brasileira: conjuntura recente e estratégias de desenvolvimento. *Indic. Econ. FEE*, v. 34, n. 1, p. 135-152, jul. 2006.

ALMEIDA, J. A evolução da capacidade de produção da indústria automobilística brasileira no período 1957-1969. *Pesq. Plan. Eco.*, v. 2, n. 1, p. 55-80, 1972.

AMARAL, M. V. S. G. **Ajuste de modelos e comparação de séries temporais para dados de vazão específica em microbacias pareadas.** 91p. 2014. Dissertação (Mestrado em Ciências), Universidade de São Paulo, Piracicaba, SP, 2014.

AVANCINI, G. T. **Estudo da volatilidade da série de preços da soja por meio de modelos GARCH e modelos ARFIMA.** 2015. 99p. Dissertação (Mestrado em Ciência), Universidade de São Paulo, Piracicaba, SP, 2015.

BAYER, F. M. **Previsão do preço e da volatilidade de commodities agrícolas, por meio de modelos ARFIMA-GARCH.** 2008. 83f. Dissertação (Mestrado em Engenharia de Produção), Universidade de Santa Maria, Santa Maria, 2008.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis Forecasting and Control.** San Francisco: Holden-Day, 1970, 537p.

CONSONI, F. L.; CARVALHO, R. Q. Desenvolvimento de produtos na indústria automobilística brasileira: perspectivas e obstáculos para a capacitação local. *RAC*, v. 6, n. 1, p. 39-61, 2002:

FLIGENSPAN, F. B.; CALANDRO, M. L. Novos investimentos na indústria automobilística brasileira: o caso gaúcho. *Indic. Econ. FEE*, Porto Alegre, v. 30, n. 3, p. 5-30, 2002.

FURLAN, C. P. R. **Especificação do tamanho da defasagem de um modelo dinâmico.** 2009. 116f. Dissertação (Mestrado em Estatística), Universidade Federal de São Carlos, São Carlos, SP, 2009.

GRETL TEAM. **Econometric software for the GNU generation.** 2017.

GUARNIERI, J. P. et al. **Análise do impacto da crise econômica na previsão de produção de automóveis no mercado brasileiro, via modelos Box**

&Jenkins. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 29. , 2009.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais.** 2 ed. São Paulo: Blucher, 2006, 546 p.

SESSO FILHO, U. A. **Indústria automobilística no Paraná: impactos na produção local e no Restante do Brasil.** Revista Paranaense de Desenvolvimento, Curitiba, n.106, p.89-112, 2004.

SHAFER, S. M.; MEREDITH, J. R. **Operations Management.** New York: John Wiley & Sons, 1998.

TEODORO, V. A. **Modelos de séries temporais para temperatura em painéis de cimento-madeira.** 96 f. 2015. Dissertação (Mestrado em Ciências), Universidade de São Paulo, Piracicaba, 2015.

VANALLE, R. M.; SALLES, J. A.A. Relação entre montadoras e fornecedores: modelos teóricos e estudos de caso na indústria automobilística brasileira. **Gest.Prod.**, v. 18, n. 2, p. 237-250, 2011.

WALTER, O. M. F. C. et al. **Previsão de vendas para um modelo de automóvel popular com a metodologia Box e Jenkins.** In: SEPROSUL, 10, Santiago, 2010.

WERNER, L.; RIBEIRO, J. L. D. **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.** **Gest. Prod.**,v. 10, n. 1, p. 47-67, abr. 2003.