

Aplicação de um modelo SARIMA na previsão de vendas de motocicletas

Application of a SARIMA model in forecasting motorcycle sales

Olga Maria Formigoni Carvalho Walter

Engenheira de Produção, Mestre em Engenharia de Produção e Doutoranda em Engenharia de Produção pela Universidade Federal de Santa Catarina – UFSC.
Santa Catarina, SC– Brasil.
olgaformigoni@gmail.com

Elisa Henning

Engenheira Civil, Doutora em Engenharia de Produção, Professora da Universidade do Estado de Santa Catarina – UDESC.
Santa Catarina, SC– Brasil.
elisa.henning@udesc.br

Graciela Moro

Licenciatura em Matemática, Mestre em Matemática Aplicada, Professora da Universidade do Estado de Santa Catarina – UDESC.
Santa Catarina, SC– Brasil.
gracimoro@gmail.com

Robert Wayne Samohyl

Economista, Doutor em Economia, Professor Titular da Universidade Federal de Santa Catarina – UFSC.
Santa Catarina, SC– Brasil.
samohyl@yahoo.com

Resumo

A frota nacional de motocicletas sofreu forte expansão na última década. Todavia, em virtude da variação da demanda a que seu mercado está exposto, intensificou-se a necessidade de previsões de vendas mais efetivas que garantam tomadas de decisões estratégicas e alocação de recursos das montadoras. Neste artigo, tem-se como objetivo estudar um modelo de previsão de vendas, baseado na metodologia Box e Jenkins. Foi utilizada a série de vendas mensal dos anos de 2006 a 2010 das motocicletas mais comercializadas no Brasil. O modelo selecionado foi um Autorregressivo Integrado de Média Móvel Sazonal (SARIMA), tendo como critério de escolha os valores do erro percentual absoluto médio, U-Theil e o AIC. Previsões de vendas para o ano de 2011 foram realizadas e comparadas com os valores reais, permitindo concluir que o modelo SARIMA é uma alternativa viável para a série temporal analisada.

Palavras-chave: ARIMA. Motocicletas. Previsão de vendas. SARIMA.

Abstract

The national fleet of motorcycles has experienced strong growth over the last decade. However, due to the varying demand to which this market is exposed, there is an increasing need for more effective sales forecasts that can ensure strategic decision making and allocation of resources. This study proposes a model for sales forecasting based on the Box-Jenkins methodology. We used the monthly sales figures of the most widely sold motorcycles in Brazil for the years 2006 to 2010. The selected model was a Seasonal Autoregressive Integrated Moving Average (SARIMA), with the criteria for choosing parameter values being the mean absolute percentage error, Theil's U statistic and AIC. Sales forecasts for the year 2011 were performed and compared to the actual values allowing to conclude that the SARIMA model is a viable prediction alternative for the series analyzed.

Key words: ARIMA. Motorcycles. Sales forecast. SARIMA.

1 Introdução

A utilização de modelos formais de previsão ajuda as organizações a dimensionarem a quantidade de bens que irão produzir ou serviços que prestarão, de modo que possam atender o mercado da melhor maneira possível. A previsão de demanda é parte integrante do processo decisório, devido a sua importância na determinação dos recursos necessários, que são as bases do planejamento estratégico da produção, das vendas e das finanças da gestão empresarial (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; TUBINO, 2007).

A previsão de vendas é fundamental para o sucesso de qualquer negócio e seu bom dimensionamento traz benefícios para clientes, fornecedores e fabricantes. Quanto mais acurada for a previsão de vendas, melhor para os clientes, que não se decepcionarão com a falta de produtos; assim como para o fabricante e para seus fornecedores, que não perderão vendas por motivo de rupturas e não enfrentarão excesso de estoques por falta de demanda.

A indústria de motocicletas passou por uma fase de grande expansão, principalmente na última década. Esse mercado, que não foi economicamente relevante até a década de 1990, sofreu fortes mudanças a partir do processo de liberalização econômica iniciado em 1994, associado a intensos processos de mudança em escala global. Políticas federais apoiaram a massificação do uso da motocicleta, que passou a ser intensamente utilizada em serviços de entrega (VASCONCELLOS, 2008; FIGUEIREDO, 2012).

Um dos fatores que impulsionaram as vendas de motocicletas no Brasil foi a possibilidade de financiamento em longo prazo, permitindo pagar mensalmente quase o mesmo valor com que se gasta com o transporte coletivo (LEITE, 2011). Outros fatores que contribuem para essa absorção

da cultura da motocicleta em todo o país estão relacionados à economia no gasto com combustível e à mobilidade (MATOS, 2008; NUNES et al., 2009; MONTENEGRO, 2010).

Todavia, em decorrência da crise econômica mundial que atingiu fortemente a produção industrial em 2008, várias foram as expectativas sobre os resultados de volume de vendas divulgadas pela Federação Nacional da Distribuição de Veículos Automotores no Brasil (FENABRAVE), conforme atestam algumas publicações (ABRACICLO, 2011a; CALDEIRA, 2011; LEITE, 2011; O GLOBO, 2011, OLIVEIRA, 2011; SILVA; CARDOSO; SANTOS, 2011). E, recentemente, determinadas medidas governamentais, como o aumento do Imposto Sobre Operações Financeiras (IOF) de 1,5% para 3,0% para conter o avanço da inflação, também têm influenciado a queda nas vendas (INFOMOTO, 2011b).

Diante desse contexto de um ambiente de incertezas com relação ao volume de vendas e da escassez de trabalhos nacionais relacionados ao tema, neste estudo, tem-se como objetivo analisar um modelo de previsão de demanda por meio da metodologia Box e Jenkins, que melhor se adapte a característica desse mercado. Como esse é um setor que busca por inovação tecnológica e utiliza altos investimentos, é necessário conhecer o comportamento da evolução de sua demanda para que seja possível elaborar estratégias competitivas de negócios por parte dos fabricantes (FIGUEIREDO, 2012). Previsões na indústria automotiva são obtidas a partir de pesquisas de mercado, técnicas Delphi, previsão ingênua, suavização exponencial, regressão múltipla, decomposição, e modelos ARIMA, entre outros (SHAHABUDDIN, 2009; WANG; CHANG; TZENG, 2011).

No Brasil, poucos trabalhos abordam modelos de previsão de séries temporais para a demanda de crescimento da frota de motocicletas. Nunes et al. (2009) aplicam modelos de suavização expo-

nencial em uma concessionária de motocicletas a fim de solucionar problemas de gestão de estoques e planejamento orçamentário. Figueiredo (2012) utiliza o modelo de difusão de Bass para o estudo e previsão dos ciclos de difusão de marcas e modelos de motocicletas comercializadas com o intuito de identificar o que tem impacto na sua comercialização.

Neste trabalho, as previsões geradas a partir do modelo selecionado poderão, de certa forma, melhor direcionar as atividades e decisões das organizações envolvidas com a produção e vendas de motocicletas. Além disso, o modelo pode servir de subsídio para outros estudos, como, por exemplo, no planejamento de transportes.

Este trabalho está assim estruturado: na seção 2 são introduzidos os conceitos de séries temporais; na 3, descreve-se a metodologia Box-Jenkins; na 4, apresentam-se os procedimentos metodológicos; na 5, encontram-se os resultados e discussão das propostas avaliadas e, para finalizar, na seção 6 estão as conclusões e considerações finais.

2 Séries temporais

As séries temporais representam um conjunto de observações ordenadas no tempo e fundamentadas na ideia de que a história dos acontecimentos, ao longo deste, pode ser usada para prever o futuro. A previsão de uma série temporal é o estabelecimento dos valores futuros da série, sendo uma previsão a estimativa acerca da verossimilhança de eventos futuros, baseados na informação atual e histórica. Pressupõe a modelagem matemática do fenômeno, obtenção de conclusões e avaliação do modelo em termos de precisão (SOUZA; CAMARGO, 2004).

Segundo Tubino (2007), as previsões de demanda baseadas em séries temporais partem do

princípio de que a demanda futura será uma projeção dos valores passados, não sofrendo influência de outras variáveis. Métodos estatísticos de previsão de séries temporais buscam identificar um padrão de comportamento da série e utilizá-lo para prever os valores futuros.

Estas séries, em sua grande maioria, apresentam características repetitivas que podem ser utilizadas no momento de realizar previsões. Um modelo clássico para séries temporais supõe que a série possa ser escrita como o agrupamento dos três seguintes componentes: tendência, ciclo e sazonalidade; e o processo de construção de valores previstos para a série é realizado por meio da reunificação de cada um desses componentes (SOUZA; SAMOHYL; MIRANDA, 2008).

Um modelo é uma descrição probabilística de sua série temporal e cabe ao usuário definir como aplicá-lo, levando em conta seus objetivos (MORETTIN; TOLOI, 2004). Um modelo pode levar a um procedimento de previsão; e os procedimentos baseados em séries temporais, deixam “os dados falarem por si”, para a construção deste. Assim, utilizam unicamente as observações da própria série de dados, não dependendo de nenhuma variável externa para efetuar as previsões. Ressalta-se que a previsão não constitui um fim em si, mas apenas um meio de fornecer informações para uma posterior tomada de decisões, visando a objetivos específicos.

3 Modelos ARIMA

O modelo Autorregressivo Integrado de Média Móvel – *Autoregressive Integrated Moving Average* (ARIMA) é um procedimento popular entre os modelos estatísticos de análise de séries temporais (LEE; KO, 2011). Esse modelo foi proposto por Box e Jenkins na década de 1970 e tem origem nos modelos autorregressivo (AR), médias

móveis (MA) e da combinação dos modelos AR e MA (ARMA). Além de incluir modelos não estacionários (ARIMA) e sazonais (SARIMA). Cada um destes modelos pode modelar uma série isolada ou combinadamente.

No modelo AR(p), o valor atual da série é expresso como um agregado linear de p valores anteriores e um ruído aleatório. Segundo Box e Jenkins (1976), Morettin e Toloi (2004), Ehlers (2009) e Lee e Ko (2011), um modelo AR(p) é dado pela equação

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \tag{1}$$

em que p é a ordem de AR, Z_t é a série temporal observada no momento t , a_t é o ruído aleatório em uma distribuição normal com média 0 e variância igual a 1 e ϕ_1, \dots, ϕ_p são os parâmetros de AR(p). Ao introduzir o operador de defasagem B , que define $Z_{t-1} = BZ_t$; e, conseqüentemente, $Z_{t-p} = B^p Z_t$, a Equação (1) pode ser reescrita por

$$\phi_p(B)Z_t = a_t \tag{2}$$

em que $\phi_p(B)$ é o operador de AR(p), definido por $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$.

O modelo MA (q), que explora a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores é descrito pela equação (BOX; JENKINGS, 1976; MORETTIN; TOLOI, 2004; EHLERS, 2009; LEE; KO, 2011):

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \tag{3}$$

e pode ser reescrito pela

$$Z_t = \theta_q(B)a_t \tag{4}$$

em que q é a ordem de MA(q), $\theta_1, \dots, \theta_q$ são os parâmetros do modelo MA(q), e $\theta_q(B)$ o qual é definido por $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$. Para aumentar a flexibilidade na adaptação de séries temporais as Equações (2) e (4) são combinadas para obter o modelo ARMA (p, q) que apresenta processos mistos AR(p) e MA(q), dado por

$$\phi_p(B)Z_t = \theta_q(B)a_t \tag{5}$$

Os modelos AR, MA e ARMA são utilizados quando a série é estacionária, ou seja, suas propriedades estatísticas básicas, como média, variância e covariância, permanecem constantes ao longo do tempo (HANKE; WICHERN; REITSCH, 2001; GUJARATI, 2006). Entretanto, quando a série é não estacionária, ela é transformada em uma série estacionária por meio do processo de diferenciação dos dados. Assim, além dos modelos previamente descritos, é utilizada a componente de integração I(d), resultando no modelo ARIMA(p, d, q) representado por

$$\phi_p(B)\Delta^d Z_t = \theta_q(B)a_t \tag{6}$$

em que $\Delta^d Z_t = (1 - B)^d Z_t$ e d é a ordem de diferenciação.

Muitas séries temporais apresentam padrões repetitivos que aparecem regularmente a cada intervalo de tempo. Como é o caso das indústrias, em que vendas e produção seguem uma sazonalidade forte em determinados períodos do ano. Para lidar com as séries que apresentam autocorrelação sazonal, Box e Jenkins (1976) generalizaram o modelo ARIMA e definiram o modelo ARIMA sazonal multiplicativo, conhecido como SARIMA(p, d, q)(P, D, Q) e representado por

$$\phi_p(B)\Phi_p(B^S)\Delta^d \Delta_s^D Z_t = \theta_q(B)\Theta_q(B^S)a_t \tag{7}$$

em que $\Delta_s^D Z_t = (1 - B^s)^D Z_t$, D é a ordem de diferenciação sazonal, $\Phi_p(B^s)$ é operador sazonal AR(p) definido por $\Phi_p(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^{2s}) - \dots - \Phi_p(B^{ps})$; $\Theta_Q(B^s)$ é o operador sazonal MA(q) por $\Theta_Q(B^s) = 1 - \Theta_1(B^s) - \Theta_2(B^{2s}) - \dots - \Theta_Q(B^{Qs})$, e Φ_1, \dots, Φ_p são parâmetros do modelo sazonal AR(p) e $\Theta_1, \dots, \Theta_Q$ são parâmetros do modelo sazonal MA(q).

3.1 Etapas da metodologia Box-Jenkins

A metodologia Box-Jenkins é definida por um ciclo composto de três etapas iterativas: identificação do modelo, estimativa de parâmetros e diagnóstico, representadas na Figura 1.

Na etapa de identificação do modelo, primeiramente há uma preparação dos dados, em que se realiza a diferenciação para estacionar a série, se necessário. Em seguida, tradicionalmente a seleção do modelo ocorre mediante a observação das funções autocorrelação (FAC) e autocorrelação parcial (FACP).

Uma vez que um modelo é identificado, estimam-se os parâmetros. O último passo na construção do modelo é a verificação de sua adequação por meio do diagnóstico. Procede-se a análise dos resíduos do modelo a fim de identificar seu comportamento como o de uma distribuição normal e como um ruído branco.

Se o modelo selecionado não for adequado, um novo deve ser identificado, seguindo as mesmas etapas. Esse processo pode ser repetido várias vezes até que um modelo satisfatório seja encontrado. Dessa forma, o modelo final selecionado pode então ser utilizado para fins de previsão.

3.2 Medidas de erros de previsão

Todos os modelos de previsão têm uma incerteza associada e para tal é necessária a mensuração desta. Existem diversos índices que medem os erros de previsão. Tais índices auxiliam a verificar

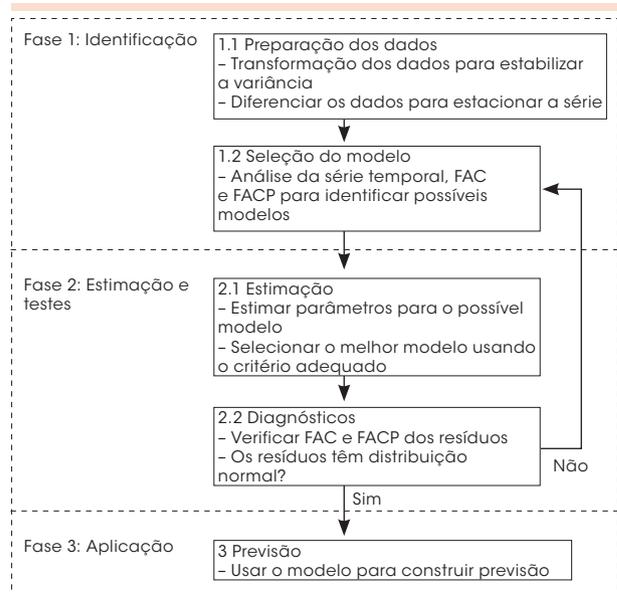


Figura 1: Etapas da construção do modelo de previsão via metodologia Box-Jenkins

Fonte: Adaptado de Makridakis, Wheelwright e Hyndman (1998).

quais modelos produzem a melhor estimativa possível, como, por exemplo, o erro percentual absoluto médio, $MAPE = (1/n) \sum_{t=1}^n |e_t / x_t|$, em que e_t corresponde à diferença entre o valor observado x_t e o previsto (SOUZA; SAMOBYL; MIRANDA, 2008).

Outro índice utilizado para a seleção dos modelos é o critério de informação de Akaike – *Akaike Information Criterion* (AIC), que é definido como $AIC = -2\log(L) + 2m$, sendo L a função de verossimilhança do modelo ARIMA ajustado; e m , o número de parâmetros do modelo (EHLERS, 2009). Ao comparar dois ou mais modelos, o escolhido será aquele que apresentar o menor valor de AIC. Valores menores indicam modelos mais próximos à realidade, ou que têm menos perda de informação em relação à realidade (GUJARATI, 2006).

Uma forma adicional de medir a capacidade preditiva de um modelo é comparar seus erros de previsão com aqueles do passeio aleatório. Uma estratégia simples consiste em tomar a observação mais recente como a melhor previsão de um valor futuro da série, ou seja, a previsão um passo

a frente do passeio aleatório. Isto é feito por meio da estatística U de Theil, definida pela equação (EHLERS, 2009):

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} (x_{t+1} - \hat{x}_t)^2}{\sum_{t=1}^{n-1} (x_{t+1} - x_t)^2}} \quad (8)$$

Valores para U maiores que 1 (um) são uma indicação de que globalmente os erros de previsão tendem a ser grandes em relação ao erros de um passeio aleatório (EHLERS, 2009).

4 Materiais e métodos

A série temporal estudada é apresentada na Tabela 1 e corresponde a 72 observações do registro mensal de vendas no Brasil de motocicletas de 101 a 150 cilindradas de marcas diversas, entre o período de janeiro de 2006 e dezembro de 2011. Essa faixa de cilindradas foi escolhida devido ao fato de ser a mais comercializada no país (ABRACICLO, 2011b). Dados de 2011 foram reservados para comparação com as previsões.

Tabela 1: Vendas mensais de motocicletas de 101 cc a 150 cc (em quantidade)

Mês/Ano	2006	2007	2008	2009	2010	2011
Jan	73.895	107.134	142.144	82.013	104.777	134.014
Fev	87.688	88.925	125.023	79.969	96.092	134.840
Mar	97.433	108.838	139.411	108.789	146.714	142.584
Abr	86.091	103.640	144.561	142.022	124.370	144.727
Mai	105.762	109.834	139.966	131.724	137.019	157.976
Jun	88.494	95.057	140.697	110.760	116.104	127.242
Jul	67.453	72.536	122.470	97.793	122.749	132.285
Ago	104.526	138.227	146.910	120.272	135.204	165.326
Set	91.406	110.278	152.310	119.783	143.966	143.394
Out	101.985	132.764	102.148	117.367	135.517	141.690
Nov	104.611	125.081	93.500	99.954	144.329	142.293
Dez	65.548	61.835	84.492	83.052	93.294	77.361
Total	1.074.892	1.254.149	1.533.632	1.293.498	1.500.135	1.643.732

Fonte: Abraciclo (2012).

Neste trabalho, como medidas de erro de previsão, serão utilizados o MAPE (Erro percentual absoluto médio), o AIC e a estatística U de Theil. Todo o tratamento estatístico dos dados foi feito com o *software* R (R DEVELOPMENT CORE TEAM, 2012), com auxílio do pacote *forecast* (HYNDMAN; KHANDAKAR, 2008).

5 Análise e discussão dos resultados

A aplicação foi realizada de acordo com as etapas da Figura 1. Para a identificação do modelo, inicialmente, construiu-se um gráfico da série original (Figura 2) e, na Tabela 2, apresentam-se suas medidas descritivas. A série temporal utilizada na estimação do modelo é composta por 60 observações (janeiro de 2006 a dezembro de 2010), possuindo uma média estimada $\bar{Z} = 110938$.

Tabela 2: Análise descritiva da série

N	60
Média	110.938
Desvio-padrão	23.887,80
Mínimo	6.835
Máximo	152.310
Amplitude	90.475
Curtose	1,49502
Coeficiente de variação	21,53%

Fonte: Os autores.

No gráfico da série (Figura 2), não é possível identificar se ela é ou não estacionária. Assim, parte-se para a observação dos correlogramas (Figura 3). A partir do gráfico da função de autocorrelação amostral (FAC) da Figura 3a, verifica-se que a série pode não ser estacionária, optando-se por um teste específico para avaliar a estacionariedade.

A estacionariedade da série é confirmada pelo teste de hipótese de Dickey Fuller. A hipótese

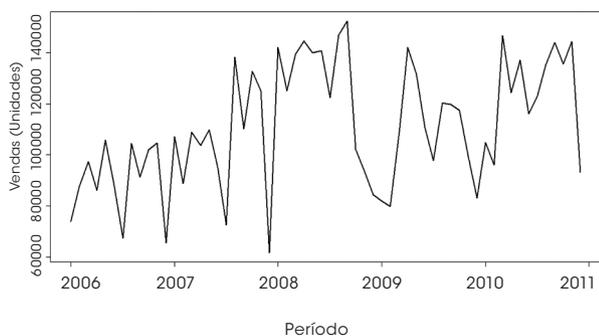


Figura 2: Vendas de motocicletas de 100 cc a 150 cc entre o período de janeiro/2006 a dezembro/2010

Fonte: Os autores.

nula de que a série é não estacionária foi rejeitada ($p\text{-valor} = 0,03865$). Já o gráfico da função de autocorrelação parcial (FACP) da Figura 3b revela um comportamento aproximadamente senoidal, e o da função de autocorrelação (FAC) mostra a primeira defasagem significativa, sugerindo a possibilidade de ser um modelo MA.

Quanto à sazonalidade, o gráfico da Figura 2 não traz informações muito claras, mas sugere um comportamento sazonal, uma vez que as vendas apresentam quedas em períodos específicos do ano. O gráfico sazonal da Figura 4 reforça esse comportamento, indicando quedas de venda nos meses de janeiro, julho e dezembro.

A Tabela 3 apresenta os modelos preliminares identificados. O modelo identificado foi escolhido mediante forma automática por meio do pacote *forecast* disponível no *software* R. O pacote retornou um modelo SARIMA $(1,0,1)(1,0,1)_{12}$. Todavia, seria interessante verificar um modelo que incluísse uma diferença sazonal, por conta do comportamento da FACP. Assim, aproximou-se um modelo SARIMA $(1,0,1)(2,1,0)_{12}$. O desempenho de cada um dos modelos apresentados, tanto dentro quanto fora da amostra, pode ser visualizado na Tabela 3.

Por meio da Tabela 3, observa-se que o modelo 2 é o melhor, uma vez que apresentou menores valores de AIC, MAPE e U-Theil. Assim, efetuou-

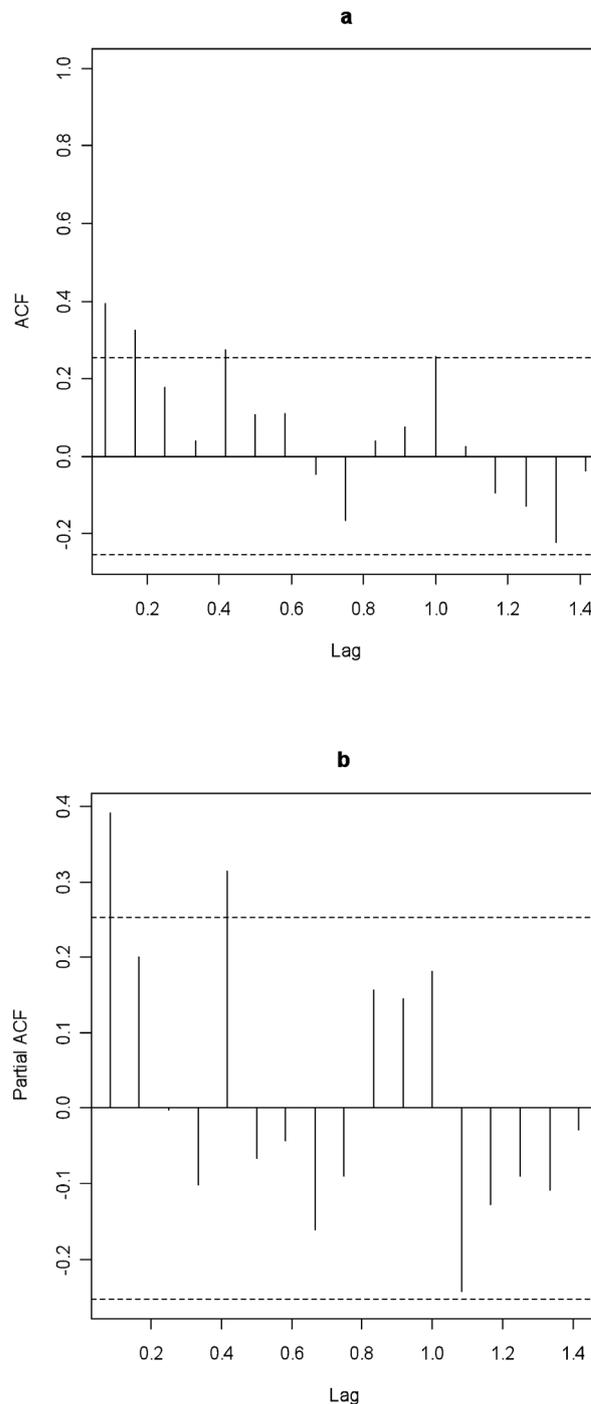
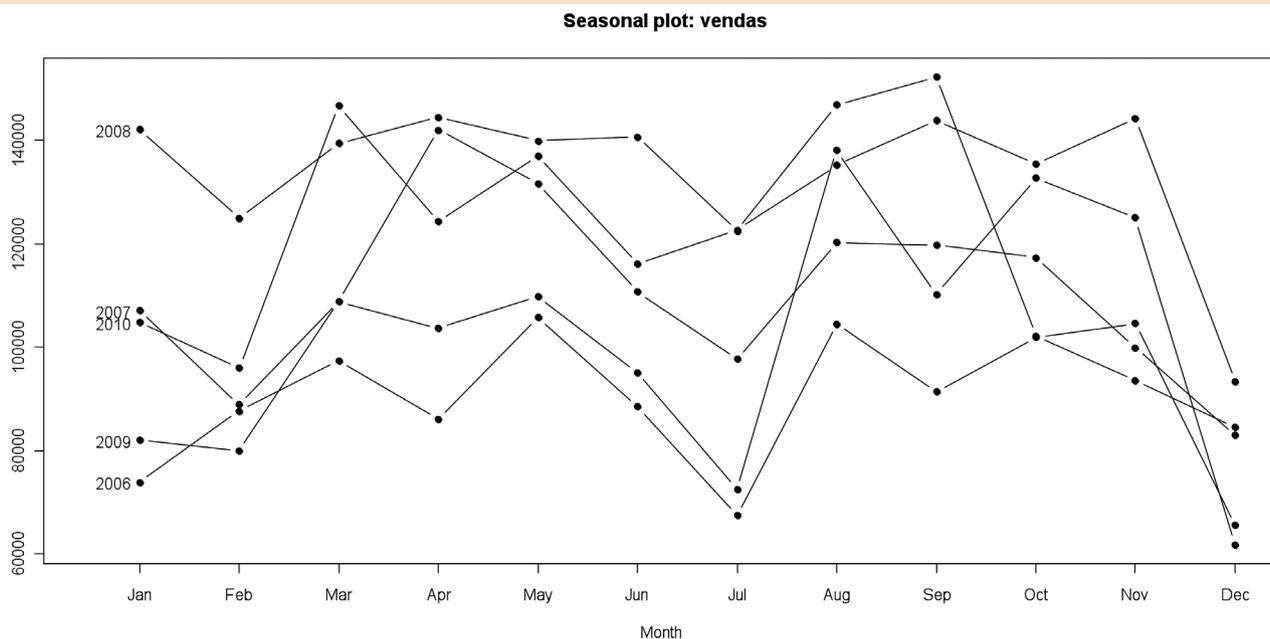


Figura 3: Correlograma das funções de autocorrelação (a) e de autocorrelação parcial (b)

Fonte: Os autores.

se a análise dos resíduos para avaliar a adequação deste. Os resíduos do modelo não apresentam autocorrelação (conforme Figuras 5a e 5b). Para a verificação da normalidade, foi construído um


Figura 4: Gráfico das vendas por mês

Fonte: Os autores.

Tabela 3: Medidas dos erros de previsão

Modelos	1 - SARIMA (1,0,1)(1,0,1) ₁₂		2 - SARIMA (1,0,1)(2,1,0) ₁₂	
	Dentro da amostra	Fora da amostra	Dentro da amostra	Fora da amostra
MAPE	12,4501	13,0334	8,9428	9,5380
AIC	1.362,12		1.090,17	
U-Theil		0,8227		0,5409

Fonte: Os autores.

histograma (Figura 6a), um gráfico de probabilidade normal (Figura 6b) e aplicado o teste Jarque Bera, ao nível de 5%. A análise destes indica que resíduos seguem uma distribuição normal.

Os parâmetros estimados para o modelo 2 são apresentados na Tabela 4.

Tabela 4: Estimativa de parâmetros do modelo 2 - SARIMA(1,0,1)(2,1,0)₁₂

Coefficiente	ϕ_1	θ_1	Φ_1	Φ_2
Estimativa	0,9448	-0,6104	-0,6722	-0,5927
Erro-padrão	0,0647	0,1322	0,1320	0,1525

Fonte: Os autores.

A equação do modelo 2, resultante da equação (7), é sumarizada por:

$$Z_t = \frac{(1 + 0,6194B)\epsilon_t}{(1 - 0,9448B)(1 + 0,6722B^{12} + 0,5927B^{24})(1 - B^{12})} \quad (9)$$

As previsões geradas para o ano de 2011, a partir do modelo 2, podem ser visualizadas na Tabela 5. Estas se mostram razoáveis com relação aos dados reais, apresentando maiores variações no segundo semestre.

Todos os valores observados estão contidos no intervalo de previsão. Para 2011, a projeção de vendas da Abraciclo era de crescimento de 11% baseado no ano anterior. Na previsão gerada pelo modelo 2, esse valor ficou em torno de 10%, e o aumento real alcançou 8,7%. Verifica-se que as maiores variações ocorreram no segundo semestre de 2011, sobretudo, nos dois últimos meses do ano.

É uma característica sazonal da série estudada a queda nas vendas no mês de dezembro, tendo apresentado oscilação nesse período em todos os anos.

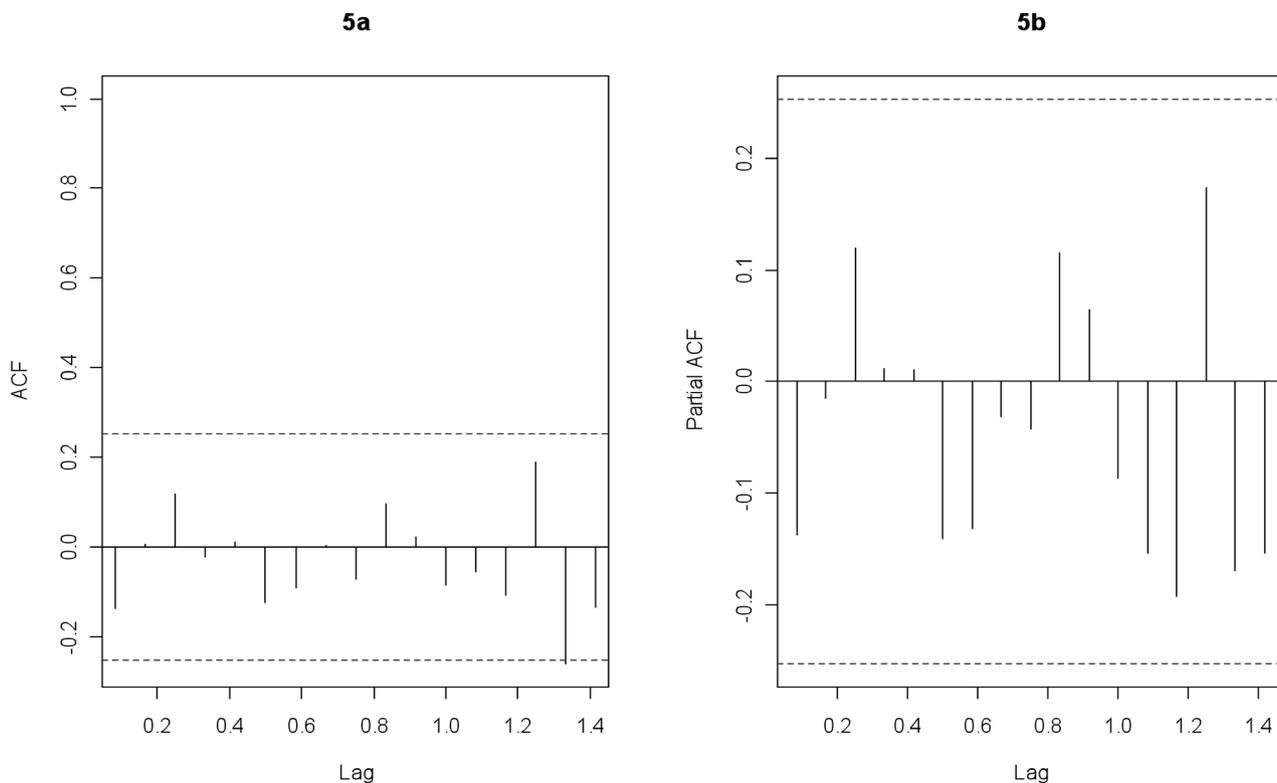


Figura 5: Gráficos da FAC (a) e da FACP (b) dos resíduos do modelo SARIMA(1,0,1)(2,1,0)₁₂

Fonte: Os autores.

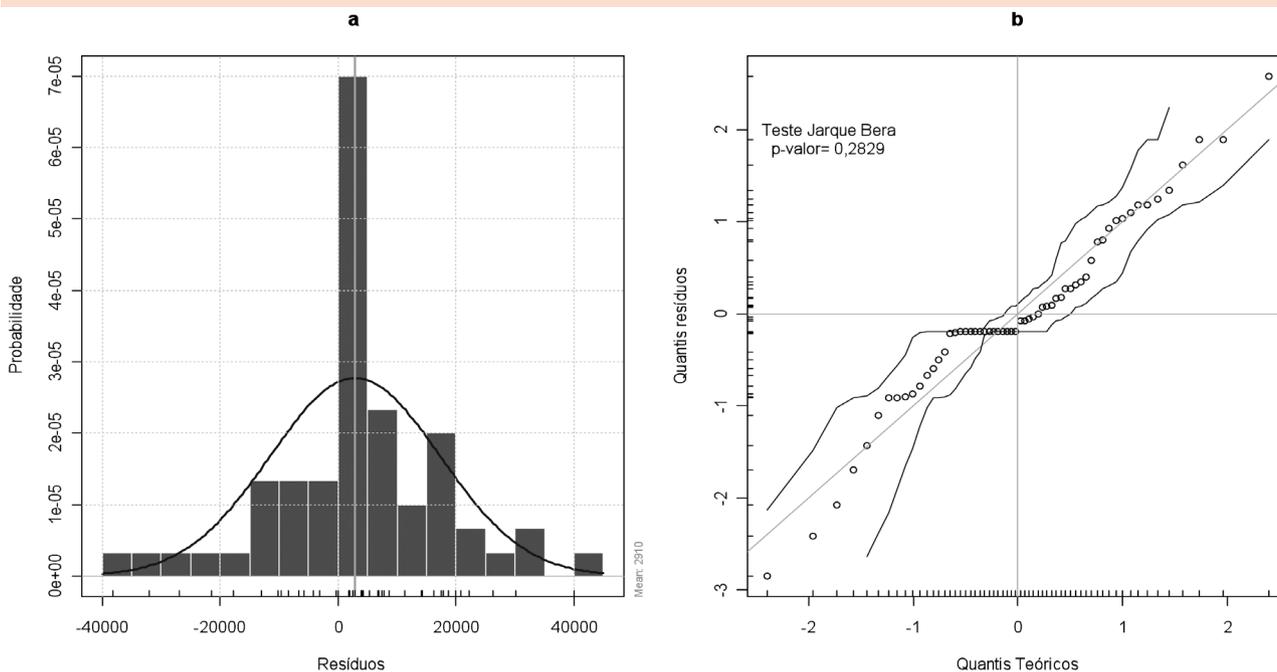


Figura 6: Histograma e gráfico de probabilidade normal dos resíduos do modelo SARIMA(1,0,1)(2,1,0)₁₂

Fonte: Os autores.

Tabela 5: Previsão para os próximos 12 períodos (intervalo de confiança de 95%)

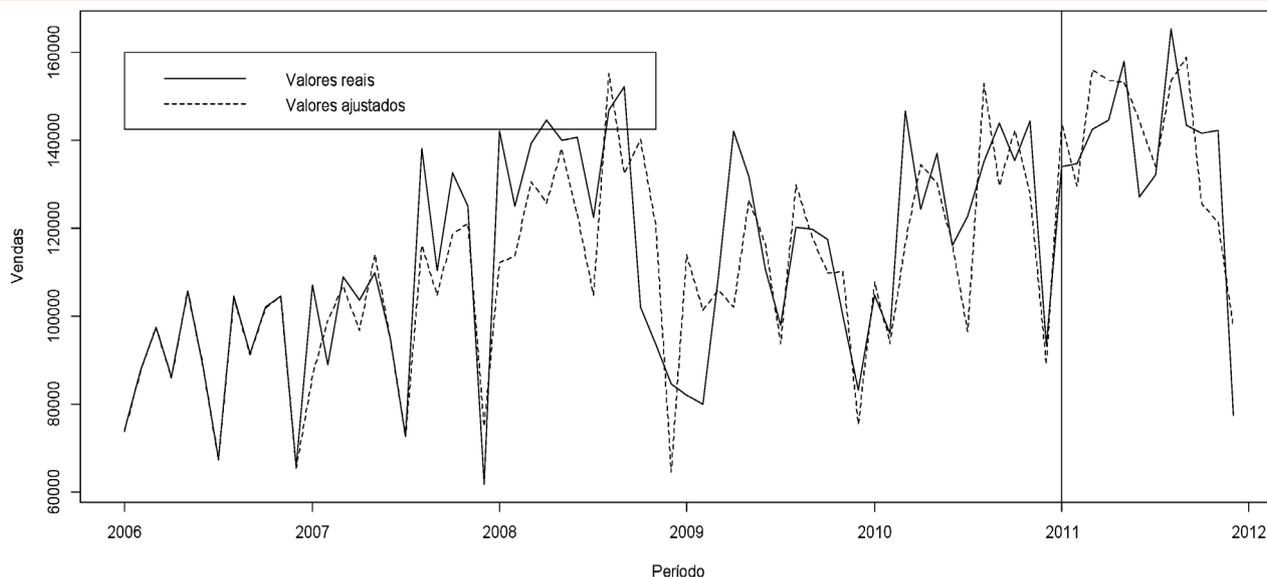
Período	Previsão de Vendas	Limite Inferior	Limite Superior	Valor observado	Erro de previsão (unid.)	Erro de previsão (%)
Jan/2011	143.956	112.029	175.882	134.014	9.942	7,42
Fev/2011	129.758	96.094	163.422	134.840	-5.082	-3,77
Mar/2011	156.187	121.046	191.328	142.584	13.603	9,54
Abr/2011	153.629	117.219	190.039	144.727	8.902	6,15
Mai/2011	153.355	115.849	190.861	157.976	-4.622	-2,93
Jun/2011	144.436	105.978	182.894	127.242	17.194	13,51
Jul/2011	133.997	94.709	173.285	132.285	1.712	1,29
Ago/2011	153.612	113.598	193.627	165.326	-11.714	-7,09
Set/2011	158.947	118.295	199.599	143.394	15.553	10,85
Out/2011	125.593	84.381	166.806	141.690	-16.096	-11,36
Nov/2011	121.347	79.641	163.054	142.293	-20.946	-14,72
Dez/2011	97.346	55.204	139.489	77.361	19.985	25,83

Fonte: Os autores.

Para complementar, a Figura 7 contempla um gráfico com os valores reais de vendas, juntamente com os valores ajustados pelo modelo selecionado. Pode-se verificar que as previsões geradas pelo modelo fornecem estimativas de vendas razoáveis.

6 Conclusão e considerações finais

Neste trabalho, teve-se como objetivo a aplicação da metodologia Box-Jenkins na previsão de vendas de motocicletas. A utilização de um méto-

**Figura 7: Gráfico com os valores reais e ajustados pelo modelo SARIMA(1,0,1)(2,1,0)₁₂**

Fonte: Os autores.

do adequado para prever as flutuações desse produto é essencial, uma vez que apesar de esse ser um mercado em expansão, ainda apresenta constante flutuação de demanda. Assim, mediante as previsões geradas, acredita-se que será possível dimensionar melhor a organização de recursos para sua produção e comercialização.

Os modelos de séries temporais baseados na metodologia Box e Jenkins podem ser uma boa alternativa para a previsão de vendas de motocicletas. Dentre os modelos identificados, um modelo sazonal, SARIMA (1,0,1)(2,1,0)₁₂, foi selecionado e mostrou-se apropriado.

Uma das desvantagens dessa metodologia é que mais de um modelo pode ser adequado, exigindo uma análise mais complexa. Ainda sem procurar variáveis explicativas, podem-se citar os modelos de suavização exponencial, redes neurais, algoritmos genéticos ou a lógica *fuzzy*. Já os modelos explicativos, como regressão múltipla ou dinâmica, também são opções para investigações em trabalhos futuros.

Comparando os resultados das previsões geradas neste trabalho com os nacionais correlatos (NUNES et al., 2009; FIGUEIREDO, 2012), verifica-se que nenhum deles utiliza a metodologia Box e Jenkins. Entretanto, os resultados observados indicam que a metodologia Box e Jenkins é um modelo apropriado para previsão de demanda de motocicletas na indústria brasileira.

Com relação à contribuição deste artigo, pode-se afirmar que este é um dos primeiros trabalhos nacionais que procura investigar a previsão de vendas de motocicletas por meio da metodologia Box e Jenkins. Como se trata de um estudo inicial, é possível considerá-lo como ponto de partida para pesquisas subsequentes na área. Espera-se que este trabalho também contribua para a indústria fabricante de motocicletas no que tange ao planejamento de recursos de produção e otimização de seus processos estratégicos.

Referências

ABRACICLO – Associação Brasileira dos Fabricantes de Motocicletas, Ciclomotores, Motonetas Bicicletas e Similares. *Dados do setor – motocicletas – vendas*. Disponível em: <http://www.abraciclo.org.br/images/stories/dados_setor/motocicletas/vendas/2011%20vendas%20dezembro.pdf>. Acesso em: 23 fev. 2012.

ABRACICLO. *Setor duas rodas leva três anos para superar crise: 2011 finalmente alcança melhor momento histórico*. Disponível em: <http://www.abraciclo.org.br/index.php?option=com_content&view=article&id=726:setor-duas-rodas-leva-tres-anos-para-superar-crise-2011-finalmente-alcanca-melhor-momento-historico&catid=7:releases-de-2010>. Acesso em: 15 dez. 2011a.

ABRACICLO. *Dados do setor – segmentação por CC*. Disponível em: <http://www.abraciclo.org.br/index.php?option=com_content&view=article&id=8%3Asegmentacao-por-cc&catid=6%3Amotocicletas&Itemid=37>. Acesso em: 4 mar. 2011b.

BOX, G. E. P.; JENKINS, G. M. *Time series analysis forecasting and control*. San Francisco: H. Day, 1976.

CALDEIRA, A. *Vendas de motos podem chegar a 2 milhões de unidades em 2008*. Disponível em: <<http://noticias.uol.com.br/carros/ultnot/2007/12/10/ult5498u24.jhtm>>. Acesso em: 30 abr. 2011.

EHLERS, R. S. *Análise de séries temporais*. 2009. Disponível em: <<http://www.icmc.usp.br/~ehlers/stemp/stemp.pdf>>. Acesso em: 22 fev. 2012.

FIGUEIREDO, J. C. B. Modelo de difusão de Bass: uma aplicação para a indústria de motocicletas no Brasil. *Gestão Industrial*, v. 8, n. 1, p. 38-59, 2012.

GUJARATI, D. *Econometria básica*. Rio de Janeiro: Elsevier, 2006. 812 p.

HANKE, J. E.; WICHERN, D.; REITSCH, A. *Business forecasting*. 7. ed. New Jersey: Prentice Hall, 2001.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, v. 27, n. 3, p.1-22, 2008.

INFOMOTO – Agência de Notícias. *Vendas e produção de motos registraram crescimento*. Disponível em: <http://www.infomoto.com.br/noticia_ver.aspx?NoticiaID=640&Noticia=Vendas e produção de motos registraram crescimento>. Acesso em: 20 jun. 2011a.

INFOMOTO – Agência de Notícias. *Segmento de duas rodas apresenta crescimento sustentado*. Disponível em: <http://www.infomoto.com.br/noticia_ver.aspx?NoticiaID=675&Noticia=Segmento de duas rodas apresenta crescimento sustentado>. Acesso em: 3 jun. 2011b.

LEE, Cheng-Min; KO, Chia-Nan. Short-term load forecasting using lifting scheme and ARIMA models. *Expert Systems with Applications*, v. 38, p. 5902-5911, 2011.

LEITE, J. *Frota de motos triplica em dez anos*. Disponível em: <<http://clipping.cservice.com.br/cliente/visualizarmateria.aspx?materiaId=11788774&canalId=17395&clienteId=a3rcamjqKfo=&end>>. Acesso em: 30 abr. 2011.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. *Forecasting: methods and applications*. 3. ed. New York: John Wiley, 1998.

MATOS, R. H. F. *Estudo exploratório das relações de trabalho como fator de influência do comportamento humano no trânsito: caso do motofrete*. 2008. 153 f. Dissertação (Mestrado em Transportes)–Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2008.

MONTENEGRO, M. M. S. *Mortalidade de motociclistas traumatizados em acidentes de transporte no Distrito Federal, no período de 1996 a 2007*. 2010. 80 f. Dissertação (Mestrado em Saúde Coletiva)–Programa de Pós-Graduação em Saúde Coletiva, Faculdade de Ciências Médicas da Santa Casa de São Paulo, São Paulo, 2010.

MORETTIN, P.; TOLOI, C. M. C. *Análise de séries temporais*. São Paulo: Edgard Blücher, 2004. 535 p.

NUNES, C. E. C. B. et al. Aplicação dos conceitos de previsão de demandas baseadas em séries temporais em uma concessionária de motocicletas (estudo de caso). In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 29. Salvador. *Anais...* Salvador/BA: Enegep, 2009.

O GLOBO. *Concessionárias reduzem previsão para venda de motos*. Disponível em: <<http://oglobo.globo.com/economia/mat/2010/07/01/concessionarias-reduzem-previsao-para-venda-de-motos-917041085.asp>>. Acesso em: 19 jun. 2011.

OLIVEIRA, W. *Motos recuperam vendas*. Diário do Grande ABC – Santo André – SP – Automóveis – 13/04/2011. Disponível em: <<http://clipping.cservice.com.br/cliente/visualizarmateria.aspx?materiaId=11818602&canalId=17395&clienteId=a3rcamjqKfo=&end>>. Acesso em: 30 abr. 2011.

R DEVELOPMENT CORE TEAM. R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2012. Disponível em: <<http://www.R-project.org>>. Acesso em: 10 dez. 2012.

SHAHABUDDIN, S. Forecasting automobile sales. *Management Research News*, v. 32, n. 7, p. 670-682, 2009.

SILVA, E. R.; CARDOSO, B. C.; SANTOS, M. P. S. O aumento da taxa de motorização de motocicletas no Brasil. *Rev. Bras. de Administração Científica*, v. 2, n. 2, p. 51- 63, 2011.

SOUZA, G. P.; SAMOHYL, R. W.; MIRANDA, R. G. *Métodos simplificados de previsão empresarial*. Rio de Janeiro: Ciência Moderna, 2008. 181 p.

SOUZA, R. C.; CAMARGO, M. E. *Análise e previsão de séries temporais: os modelos ARIMA*. 2. ed. Rio de Janeiro: Regional, 2004.

TUBINO, D. F. *Planejamento e controle da produção*. São Paulo: Atlas, 2007. 190 p.

VASCONCELLOS, E. A. O custo social da motocicleta no Brasil. *Revista dos Transportes Públicos-ANTP*, v. 30, p. 127-142, 2008.

WANG, F. K.; CHANG, K.; TZENG, C. Using adaptive network-based fuzzy inference system to forecast automobile sales. *Expert Systems with Applications*, v. 38, n. 8, p. 10587-10593, 2011.

Recebido em 11 set. 2012 / aprovado em 3 jan. 2013

Para referenciar este texto

WALTER, O. M. F. C. et al. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. *Exacta – EP*, São Paulo, v. 11, n. 1, p. 77-88, 2013.