

PREVISÃO DE VENDAS DE MOTOCICLETAS APLICANDO MODELOS SARIMA, SUAVIZAÇÃO EXPONENCIAL E COMBINAÇÃO DE PREVISÕES

Elisa Henning, UDESC, elisa.henning@udesc.br
Amanda Caroline Martin, UDESC, amandacarolinemartin@gmail.com
Olga Maria Formigoni Carvalho Walter, UDESC, olgaformigoni@gmail.com
Ana Mirthes Hackenberg, UDESC, ana.hackenberg@udesc.br
Katiani da Conceição Loureiro, UDESC, katiani.loureiro@udesc.br

Resumo: Observa-se que não só no Brasil, mas também em outros países, há um crescente índice de motorização de veículos, especialmente a motocicleta. Esta vem representando um modo de transporte mais econômico, tanto no momento da compra quanto na sua manutenção diária. Analisar o mercado de vendas de motocicletas é essencial, pois o aumento deste modal de transporte pode estar associado a constantes e graves problemas de trânsito, tanto nas pequenas e médias cidades, bem como nos grandes centros urbanos. Sob esta ótica, o objetivo deste artigo é analisar modelos de previsão de vendas de curto prazo, baseados na metodologia Box e Jenkins, suavização exponencial e a combinação destes a partir do método da variância mínima. Os dados referem-se a quantidade de motocicletas de 101 a 150 cilindradas comercializadas no Brasil no período de janeiro de 2006 a julho de 2013. Os resultados parciais mostram um mercado com comportamento sazonal.

Palavras-chave: Previsão, Motocicletas, SARIMA, Suavização Exponencial, Combinação de Previsões.

MOTORCYCLE SALES FORECAST APPLYING SARIMA MODELS, EXPONENTIAL SMOOTHING AND COMBINATION OF FORECASTS

Abstract: That not only is observed in Brazil, but also in other countries, there is a growing index of engine vehicles, especially the motorcycle. This has represented a more economical mode of transport, both at the time of purchase and in their daily maintenance. Analyze the motorcycle sales market is essential, because the increase of this mode of transport may be associated with constant and serious traffic problems, both in small and medium cities as well as in large urban centers. From this perspective, the aim of this paper is to analyze short-term sales forecasting models based on Box and Jenkins methodology, exponential smoothing, and the combination of these from the method of minimum variance. The data refer to the amount of motorcycles 101-150 cc marketed in Brazil from January 2006 to July 2013. The partial results show a market with seasonal behavior.

Keywords: Forecast, Motorcycle, SARIMA, Exponential Smoothing, Combination of Forecasts.

1. INTRODUÇÃO

Prever o crescimento do número de veículos numa cidade pode ajudar o poder público a planejar a expansão das vias urbanas e o tráfego viário. Neste sentido pesquisas de fluxo e previsão de demanda são elementos que podem contribuir para o planejamento do sistema viário e também contribuir na elaboração de políticas públicas. Por um lado, enquanto se busca incentivar modais de transporte mais sustentáveis como a bicicleta, observa-se que o aumento das frotas de automóveis e de motocicletas se constituiu em uma tendência bastante forte no país (IPEA, 2011). Esse aumento decorreu em função da elevação do poder aquisitivo das pessoas, das deficiências do transporte público e também devido ao apoio do governo federal com medidas de isenções de imposto e facilitação do crédito. Assim, entender este mercado, por meio de modelos de previsão, é essencial para embasar os estudos de planejamento viário.

De maneira geral os usuários buscam modos mais confortáveis e vantajosos para realizar suas viagens, sejam estas a trabalho ou lazer. Entre as causas que podem explicar a preferência por motocicletas está na ou a facilidade de aquisição e manutenção e na agilidade

que ela possibilita nos centros urbanos. Segundo Holtz e Lindau (2009), *apud*. Silva, Cardoso e Santos (2011), em ambiente urbano, uma viagem de sete km leva 35 minutos no transporte público rodoviário, enquanto no automóvel ou motocicleta, leva apenas 15 minutos. Além disso, a diferença entre a qualidade ofertada pelo transporte público e o transporte individual privado pode incentivar o uso de automóveis e motocicletas.

O aumento da frota de motocicletas pode resultar em fatores negativos, como acidentes de natureza grave, malefício ao meio ambiente e a saturação das vias brasileiras, sendo importantes motivos de preocupação para o planejamento de transportes no Brasil. De acordo com o Departamento Nacional do Trânsito (DENATRAN, 2010), os acidentes de trânsito custam aos cofres públicos cerca de R\$ 28 milhões por ano, sem contabilizar os custos indiretos. Já a Associação Brasileira de Medicina do Tráfego (ABRAMET, 2007), afirma que os acidentes de trânsito no país deixam cerca de cem mil pessoas com sequelas permanentes e matam em média trinta e cinco mil pessoas por ano, sendo que cinco mil são motociclistas.

Com relação ao meio ambiente, como as motocicletas possuem maior facilidade de locomoção e não se prendem em congestionamentos, ela se torna mais eficiente na queima de combustíveis, todavia há que se considerar que elas contribuem na emissão de poluente (SILVA; CARDOSO; SANTOS, 2011).

Já nas áreas urbanas, a circulação das motocicletas quase sempre ocorre em condições de tráfego misto, ou seja, motocicletas, carros, caminhões e ônibus circulam juntos. Porém, com a finalidade de fugir do trânsito congestionado, as motocicletas criam corredores entre os espaços que sobram entre um automóvel e outro. Esse corredor que se forma entre os automóveis faz fluir o contingente de motocicletas, mas também cria oportunidades de colisões de motos com os outros veículos.

Todos estes fatores justificam a necessidade de investigar o mercado de motocicletas. Este artigo tem, portanto, o objetivo principal de analisar modelos de séries temporais. Procura-se aqui avaliar o comportamento ao longo dos últimos anos. Espera-se que os resultados auxiliem a entender o comportamento deste mercado e forneça subsídios para novas análises.

2. PREVISÃO POR SÉRIES TEMPORAIS

Uma série temporal é definida como um conjunto de observações dos valores que uma variável assume em diferentes momentos de tempo (GUJARATI, 2006). Este conjunto de observações pode ser coletado a intervalos de tempo regulares, como por exemplo: diariamente (preço das ações), mensalmente (taxa de desemprego), anualmente (orçamento do governo), decenalmente (censo demográfico).

Para Tubino (2007), as previsões 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.

As séries de dados ao longo do tempo, 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 de três componentes: tendência, ciclo e sazonalidade, onde o processo de construção de valores previstos para a série é realizado através da reunificação de cada uma desses componentes (SOUZA; SAMOBYL; MIRANDA, 2008). Existem vários métodos para

previsão de séries temporais, sendo que neste artigo focaliza dois métodos, ARIMA e Suavização Exponencial.

2.1 METODOLOGIA BOX E JENKINS

Os modelos Box e Jenkins, também conhecidos como Modelos Autoregressivos Integrados de Média Móvel, ou simplesmente ARIMA (*Autoregressive Integrated Moving Average*), analisam as propriedades estocásticas ou probabilísticas das séries temporais, representando-as através de um modelo, segundo a filosofia de deixar que os dados falem por si só. O modelo ARIMA é representado por $ARIMA(p,d,q)$, onde p é o número de termos autoregressivos; d , o número de vezes que devemos diferenciar a série antes que ela se torne estacionária e q , o número de termos de médias móveis, com p , d e q inteiros maiores ou iguais a zero (GUJARATI, 2006; GUARNIERI *et al.*, 2009).

Os modelos ARIMA resultam da combinação de três componentes que também são chamados de filtros: o componente auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Nos modelos $AR(p)$ a série é descrita por seus valores passados regredidos e pelo ruído aleatório. A componente $MA(q)$ explora a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores. Já, os modelos $ARMA(p, q)$ apresentam processos mistos $AR(p)$ e $MA(q)$ e se apoiam na premissa que a série temporal 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, além dos modelos citados, é empregada uma componente de integração $I(d)$, resultando no modelo $ARIMA(p, q, d)$. Depois de calcular a diferença entre os valores subjacentes da série é possível torná-la estacionária, de modo que ofereça uma base válida para a previsão (OLIVEIRA; SOBRINHO, 2009; GUARNIERI *et al.*, 2009).

Muitas séries temporais provenientes de dados industriais apresentam padrões repetitivos que aparecem regularmente a cada intervalo de tempo. Como é o caso de indústrias, onde vendas e produção seguem uma sazonalidade forte durante o ano. Os modelos que compõem as séries que apresentam autocorrelação sazonal são conhecidos como $SARIMA(p,d,q)(P,D,Q)$, onde as letras minúsculas representam a ordem do modelo ARIMA (parte não sazonal) e as maiúsculas representam a ordem dos modelos e diferenciação sazonal (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; GUARNIERI *et al.*, 2009). Mais detalhes e demonstrações dos modelos abordados nesta seção podem ser encontrados em Makridakis, Wheelwright e Hyndman (1998), Hanke, Wichern e Reitsch (2001), Moretin e Tolo (2004) e em Gujarati (2006).

Ao trabalhar com uma série temporal procura-se estudá-la e descobrir qual seu comportamento. Assim inicia-se a busca pelo modelo que melhor represente as características da série, com o intuito de descobrir se ela pode ser mais bem representada por um processo auto-regressivo $AR(p)$, ou por um processo de médias móveis $MA(q)$, por um modelo auto-regressivo de médias móveis $ARMA(p,q)$, por um processo misto auto-regressivo integrado de médias móveis $ARIMA(p,d,q)$, ou ainda, por um modelo $ARIMA(p,d,q)$ sazonal. Através do gráfico da função de autocorrelação (FAC) e do gráfico de autocorrelação parcial (FACP), pode-se observar a indicação de estacionariedade ou não da série, bem como a informação sobre o número de parâmetros a serem estimados.

Muitas séries temporais apresentam padrões repetitivos que aparecem regularmente a cada intervalo de tempo. Para lidar com as séries sazonais, que podem apresentar autocorrelação sazonal, Box e Jenkins (1976) generalizaram o modelo ARIMA e definiram o

modelo ARIMA sazonal, conhecido como SARIMA(p,d,q)(P,D,Q) e representado pela Equação 1 por

$$\phi_p(B)\Phi_p(B^S)\Delta^d\Delta_S^D Z_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (1)$$

onde: $\Delta_S^D Z_t = (1 - B^S)^D Z_t = D$ é a ordem de diferenciação sazonal; $\Phi_p(B^S)$ = operador sazonal AR(p) definido por $\Phi_p(B^S) = 1 - \Phi_1(B^S) - \Phi_2(B^{2S}) - \dots - \Phi_p(B^{pS})$; $\Theta_Q(B^S)$ = o operador sazonal MA(q) por $\Theta_Q(B^S) = 1 - \Theta_1(B^S) - \Theta_2(B^{2S}) - \dots - \Theta_Q(B^{QS})$; Φ_1, \dots, Φ_p = parâmetros do modelo sazonal AR(p) e $\Theta_1, \dots, \Theta_Q$ = parâmetros do modelo sazonal MA(q).

O processo de modelagem segue algumas etapas específicas. Na fase inicial os dados são transformados para estabilizar a variância e diferenciados para que se tornem estacionários, se necessário. Na segunda parte desta fase ocorre a seleção do modelo de acordo com uma análise preliminar dos gráficos de correlação e autocorrelação parcial para identificar possíveis modelos que representam a série de dados. Em seguida são estimados os parâmetros do modelo. Assim que é selecionado o modelo, ocorre seu diagnóstico, onde é testada sua validade através da verificação dos gráficos de correlação e autocorrelação parcial dos resíduos gerados e se estes se apresentarem como ruído branco (variável aleatória independente com média zero e variância constante). Uma vez que o modelo atendeu os pressupostos, pode ser aplicado para previsões.

2.2 MODELO DE SUAVIZAÇÃO EXPONENCIAL

Os Modelos de Suavização exponencial têm grande popularidade devido a sua simplicidade, eficiência computacional e à sua razoável precisão (MORETTIN; TOLOI, 2004, p.87). Estes também se utilizam apenas das observações da própria série de dados, não dependendo de nenhuma variável externa e a sua metodologia consiste em decompor a série em componentes (tendência e sazonalidade) e suavizar seus valores passados, ou seja, ponderando de forma diferenciada os valores (SOUZA; SAMOHYL; MIRANDA, 2008).

A suavização ou ajuste exponencial é também um método estatístico que parte de uma equação de médias móveis, ponderadas exponencialmente, com o objetivo de produzir ajustes nas variações aleatórias dos dados de determinada série temporal. Esse procedimento de suavização utiliza uma ponderação distinta para cada valor observado na série temporal, de modo que valores mais recentes recebam pesos maiores. Assim, os pesos formam um conjunto que decai exponencialmente a partir de valores mais recentes (GARDNER, 2006).

Os métodos de previsão por suavização exponencial se utilizam apenas de observações da própria série de dados, não dependendo de nenhuma variável externa para realizar previsões. (SOUZA; SAMOHYL; MIRANDA, 2008). Esses métodos, segundo Gardner (1985; 2006), são reconhecidos como uma das ferramentas mais empregadas na previsão de curto prazo de séries temporais. Sua popularidade se deve principalmente por sua simples formulação, facilidade de ajustes e boa precisão (MAKRIDAKIS; HIBON, 2000). Os procedimentos destes métodos incorporam de maneira simples e compreensível o nível, a tendência e a sazonalidade que apresentam os dados da série temporal, assim como o erro de previsão, que é o componente estocástico do método (HYNDMANN *et al*, 2002; HYNDMANN; KHANDAKAR, 2008).

Segundo Morettin e ToloI (2004), a classificação de um método de suavização exponencial além da componente tendência pode também estar relacionada com o fator

sazonalidade e pela inclusão do erro, tanto na forma aditiva como na multiplicativa. A seguir são apresentadas as três variações básicas de suavização exponencial comumente utilizada na prática. O tipo mais simples de série temporal é aquele em que os valores da série flutuam aleatoriamente em torno de um valor fixo, sem apresentar qualquer tendência. Se a série temporal mantém-se constante sobre um nível médio, uma suavização exponencial simples proposta por Brown (1959, 1963) pode ser usada para a previsão de valores futuros da série. A suavização exponencial dupla, também conhecida como método de Holt é uma expansão da suavização exponencial simples para dados de série temporal que exibem uma tendência linear. Este método oferece refinamentos adicionais na modelagem, à medida que introduz uma constante de suavização que afeta a tendência da série.

Os métodos de suavização exponencial podem ainda ser classificados de uma forma mais geral de acordo com as componentes consideradas. Estas componentes são: tipo de tendência (aditiva, multiplicativa, aditiva ou multiplicativa amortecida) e tipo de sazonalidade (aditiva ou multiplicativa). Além dos métodos tradicionais estão os casos considerando o amortecimento. Os métodos que consideram tendência amortecida referem-se a casos onde a tendência não é linear, sendo que o amortecimento corrige este problema (SOUZA; SAMOHYL; MIRANDA, 2008). Neste sentido uma classificação mais ampla pode ser visualizada na Tabela 1, de acordo com a proposição Hyndmann *et al.* (2002). A nomenclatura utilizada corresponde ao tipo de tendência ou sazonalidade, sendo a letra “N” igual a “nenhuma”, “A” indica “aditiva” e o M, “multiplicativa”. A letra “a” minúscula implica no amortecimento da componente tendência. Apenas para ilustrar, considerando os métodos chamados de tradicionais M se o método for NN, ele não possui nem tendência nem sazonalidade, correspondendo a Suavização Exponencial Simples (SES), o método de Holt (tendência aditiva e sazonalidade) é representado por AN, Holt-Winters é indicado por AA ou AM (tendência aditiva e sazonalidade aditiva ou multiplicativa respectivamente).

Os modelos ainda podem ser classificados de acordo com o erro, aditivo ou multiplicativo. O erro multiplicativo capta a heterocedasticidade dos resíduos. Cada método possui formulação específica de acordo com as componentes consideradas. Uma das principais desvantagens da utilização dos métodos de suavização exponencial consiste em determinar os valores mais apropriados das constantes de suavização, recomendando realizar esta etapa de modo a tornar mínima a soma dos quadrados dos erros de ajustamento (MORETTIN; TOLOI, 2004).

TABELA 1 - Classificação dos métodos exponenciais quanto à tendência e sazonalidade

Tendência	Sazonalidade		
	Nenhuma	Aditiva	Multiplicativa
Nenhuma	NN	NM	NM
Aditiva	AN	AA	AM
Aditiva amortecida	AaN	AaA	AaM
Multiplicativa	MN	MA	MM
Multiplicativa amortecida	MaN	MaA	MaM

FONTE - Souza, Samohyl e Miranda (2008).

2.3 CRITÉRIOS DE AVALIAÇÃO DO MODELO

Existem vários critérios que são utilizados para avaliação de modelos concorrentes e mensurar a qualidade da previsão gerada pelo modelo. Todavia, nesta seção serão descritos apenas os aplicados neste artigo. Considerou-se para a seleção do melhor modelo ajustado, o critério de avaliação baseado no *Mean Absolute Percentual Error* (MAPE), erro percentual absoluto

médio. O erro percentual absoluto médio, representado pela Equação 2 é uma medida de erro de previsão que informa em quanto está se errando em termos percentuais na previsão.

$$\frac{1}{n} \sum_{t=1}^{i=n} \left| \frac{e_t}{O_t} \right|, \quad (2)$$

onde e_t = representa a diferença entre o valor previsto e o valor observado; O_t = valor observado e n = número de elementos previstos (SOUZA; SAMOHYL; MIRANDA, 2008).

Outra forma de medir a capacidade preditiva de um modelo consiste em comparar seus erros de previsão com aqueles do passeio aleatório. Uma estratégia simples (EHLERS, 2009) consiste em tomar a observação mais recente como a melhor previsão de um valor futuro da série, ou seja, a previsão um passo à frente do passeio aleatório, com $\hat{x}_t(1) = x_t$. Isto poder ser feito por meio da estatística U de Theil, definida pela Equação (3),

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} (x_{t+1} - \hat{x}_t)^2}{\sum_{t=1}^{n-1} (x_{t+1} - x_t)^2}}. \quad (3)$$

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

2.4 COMBINAÇÃO DE MODELOS

Para incorporar diferentes previsões originadas de diferentes técnicas, uma opção é aplicar um método conhecido como combinação de previsões. Esta técnica é frequentemente utilizada para melhorar a acurácia de previsões. Apresentada inicialmente por Bates e Granger (1969), a combinação de previsões é exposta como uma alternativa viável às técnicas de previsão individuais, sendo que resultados de alguns estudos apontam que combinações de previsões avaliadas apresentaram acurácia superior à das previsões individuais, representando um risco menor no desempenho da previsão em comparação com as previsões individuais (HIBON; EVGENIOU, 2005; MILANI; WERNER, 2013).

A combinação de previsões se dá por meio da estimação dos pesos de cada previsão que compõe a combinação. Estas previsões que compõem a combinação também apresentam diferentes abordagens (MILANI, WERNER, 2013). As combinações objetivas aplicadas neste trabalho são obtidas a partir do método da variância mínima. Este método, proposto por Bates e Granger (1969), consiste em realizar a combinação linear de duas previsões objetivas, de acordo com a Equação (4)

$$F_c = wF_1 + (1 - w)F_2, \quad (4)$$

onde w = o peso atribuído à previsão; F_1 e F_2 = são as previsões individuais a serem combinadas (MILANI, WERNER, 2013).

Esta estrutura de obtenção dos pesos (Equação 4) é embasada na observação das variâncias dos erros das previsões individuais e na correlação entre os erros de previsão dessas duas previsões individuais, obtidas de forma independente (MILANI, WERNER, 2013). Para atribuir menor peso às previsões de maior variabilidade, a combinação dessas previsões deve ser calculada utilizando os pesos conforme a Equação 5,

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}, \quad (5)$$

onde ρ = correspondendo ao valor da correlação linear entre os erros das previsões obtidas em F_1 e F_2 ; σ_1^2 e σ_2^2 correspondem à variância dos erros de previsão de F_1 e F_2 , respectivamente.

3. PROCEDIMENTOS METODOLÓGICOS

Os dados analisados referem-se a 84 observações de vendas mensais de motocicletas entre 101 e 150 cilindradas comercializadas no Brasil no período de janeiro de 2006 a dezembro de 2012. Escolheu-se esta faixa de cilindradas porque é a que representa maior comercialização no país. Com os dados do ano de 2013 foram realizadas as comparações com as previsões geradas (ABRACICLO, 2011, 2013).

Neste trabalho, como medidas de erro de previsão, serão utilizados o MAPE (Erro percentual absoluto médio) e a estatística U de Theil. Todo o tratamento estatístico dos dados foi feito com o *software* R (R CORE TEAM, 2014). A estimação dos modelos foi realizada com um pacote adicional do R denominado *forecast* (HYNDMANN; KHANDAKAR, 2008) voltado para modelos de previsão com procedimentos automáticos de escolha de modelos ARIMA e de Suavização Exponencial. Embora os procedimentos sejam automáticos, conforme já dito, foram construídos alguns gráficos para auxiliar na interpretação da série e posteriormente analisou-se o modelo selecionado. Antes de serem efetuadas as previsões pontuais e intervalares e posterior combinação, verificou-se a adequação do modelo, através da análise dos resíduos, de acordo com o exposto por Makridakis, Wheelwright e Hyndman (1998). Além disso, foram analisadas algumas medidas dos erros de previsão dentro e fora da amostra. Estas medidas foram também comparadas a resultados de modelos menos sofisticados, como a a previsão ingênua, previsão ingênua sazonal e por média aritmética.

4. ANÁLISE DOS RESULTADOS

Na Figura 1 está o gráfico da série original e na Figura 2 podem ser visualizados os gráficos das funções de autocorrelação amostral (ACF) e autocorrelação amostral parcial (PACF). Verifica-se, por meio dos gráficos da ACF e PACF que a série apresenta autocorrelação, com isso, é necessário diferenciá-la.

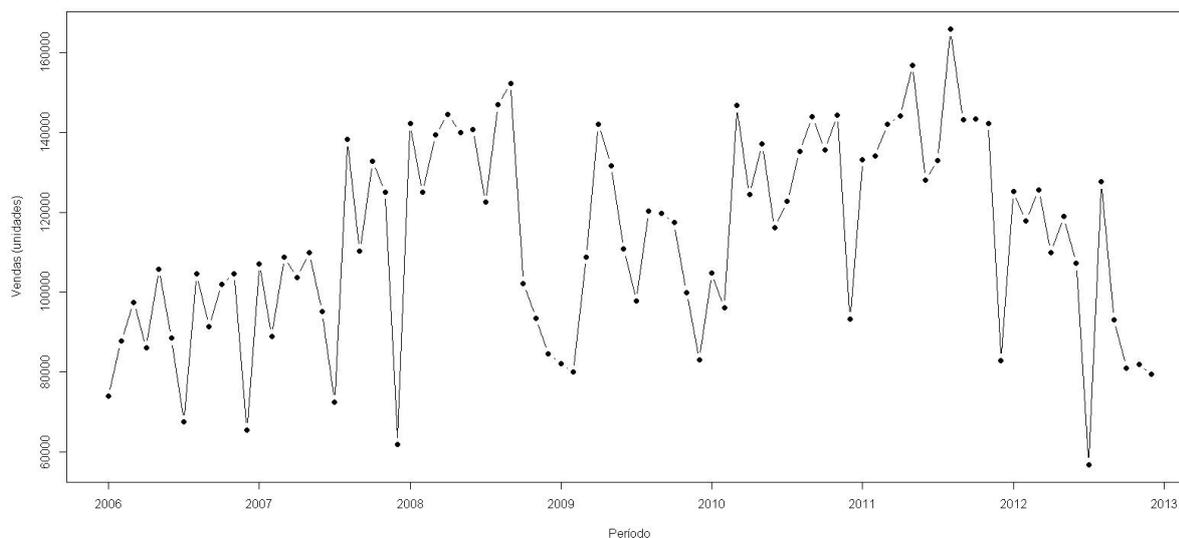


FIGURA 1 - Gráfico da série temporal das vendas de motocicletas.

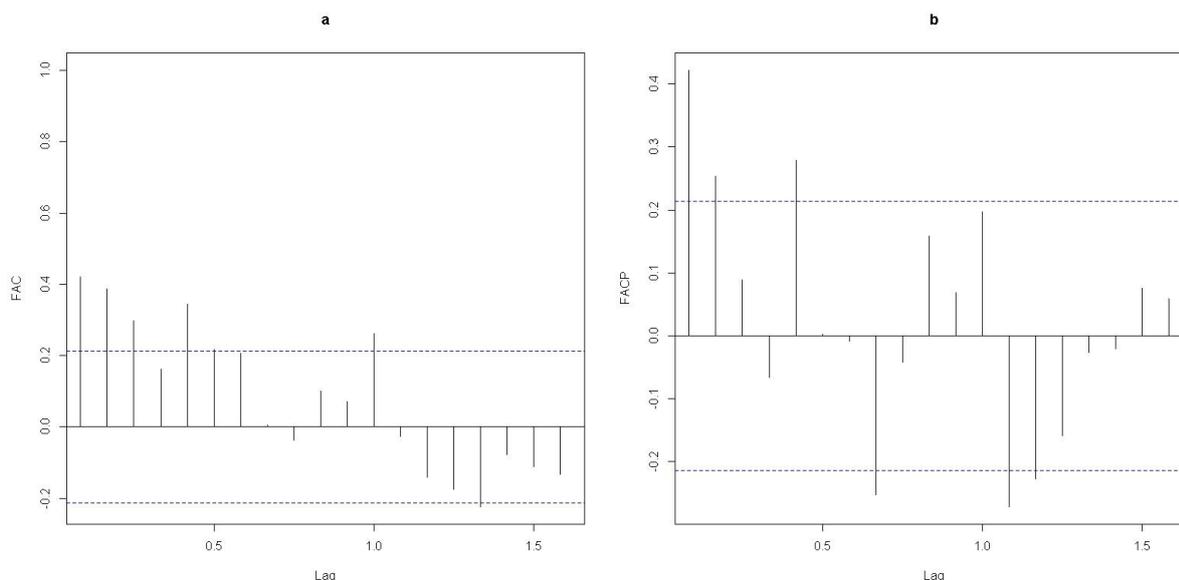


FIGURA 2 - Gráfico da série temporal das vendas de motocicletas das funções de autocorrelação (FAC) e autocorrelação parcial (FACP).

Para complementar, por meio dos testes Dickey-Fuller e Kwiatkowski-Phillips-Schmidt-Schin, confirma-se que uma diferença é necessária para a parte regular da série. O teste Canova-Hansen foi aplicado para verificar a necessidade de diferenciação na parte sazonal e, de acordo com os resultados dos testes, não é necessário diferenciar sazonalmente. Assim, após a diferenciação avaliando-se novamente os gráficos da ACF e PACF (Figura 3), dentre alguns modelos possíveis, um primeiro modelo proposto é um SARIMA $(0,1,1)(1,0,1)_{12}$ com uma diferença na parte regular. Os parâmetros estimados para o modelo são apresentados na Tabela 2. Efetuou-se a análise dos resíduos deste modelo, que não é mostrado neste documento, e os mesmos se apresentam como um ruído branco. O modelo SARIMA $(0,1,1)(1,0,1)_{12}$ proposto, portanto, é adequado para efetuar previsões.

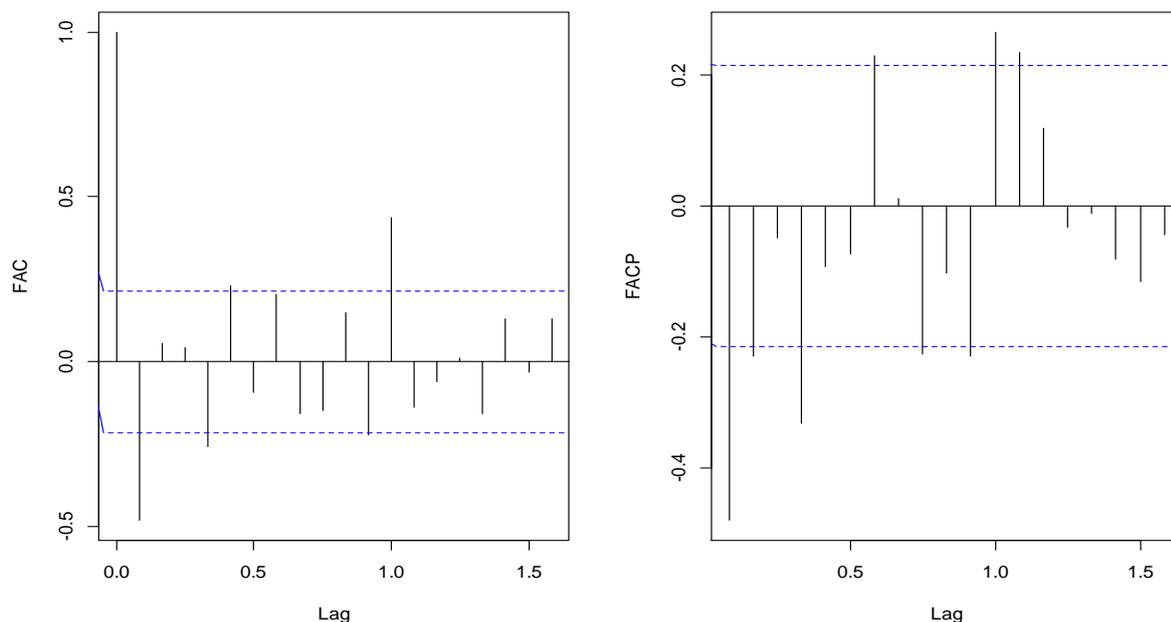


FIGURA 3 - Gráfico das funções de autocorrelação (FAC) e autocorrelação parcial (FACP) após diferenciação.

TABELA 2 - Estimativa de parâmetros do modelo SARIMA(0,1,1)(2,0,1)₁₂

Coefficiente	θ_1	Φ_1	Θ_1
Estimativa	-0,5794	0,9995	-0,9678
Erro-padrão	0,0815	0,0029	0,0943

Para a suavização exponencial, o modelo escolhido foi um ETS (A,N,A), considerando o erro aditivo (A), sem tendência (N), e com sazonalidade aditiva (A), ou seja, são quatorze parâmetros no total, sendo que dois correspondem as constantes de suavização $\alpha = 0,4349$ (nível) e $\gamma = 1e^{-04}$ (sazonalidade) e os coeficientes sazonais relativos aos meses do ano, que se encontram na Tabela 3. Os resíduos são normalmente distribuídos e não apresentaram autocorrelação. Não há motivos para a não aceitação do modelo. Os dois modelos, doravante denominados de SARIMA e ETS, concordam com relação à sazonalidade da série, isto é, que as vendas apresentam um comportamento sazonal.

TABELA 3 - Componentes sazonais mensais

Mês	Componente sazonal (s)	Mês	Componente sazonal (s)
Jan.	-37456,08	Jul.	-1498,66
Fev.	522,37	Ago.	14513,02
Mar.	4684,69	Set.	9925,22
Abr.	9653,26	Out.	10256,92
Mai.	19303,08	Nov.	-11156,81
Jun.	-13521,92	Dez.	-5225,09

O mercado de demanda das motocicletas é aqui representado por uma série sazonal, com um comportamento de diminuição nas vendas nos meses de junho, julho, novembro, dezembro e janeiro, de acordo com o sinal do coeficiente (Tabela 3). Um gráfico sazonal da série (Figura 4) ratifica o exposto. Estes períodos podem estar associados a fatores distintos,

como a estação climática ou às férias do começo do ano. A série não apresenta uma acentuada tendência de aumento (ou redução), mas por outro lado não pode ser considerada estacionária.

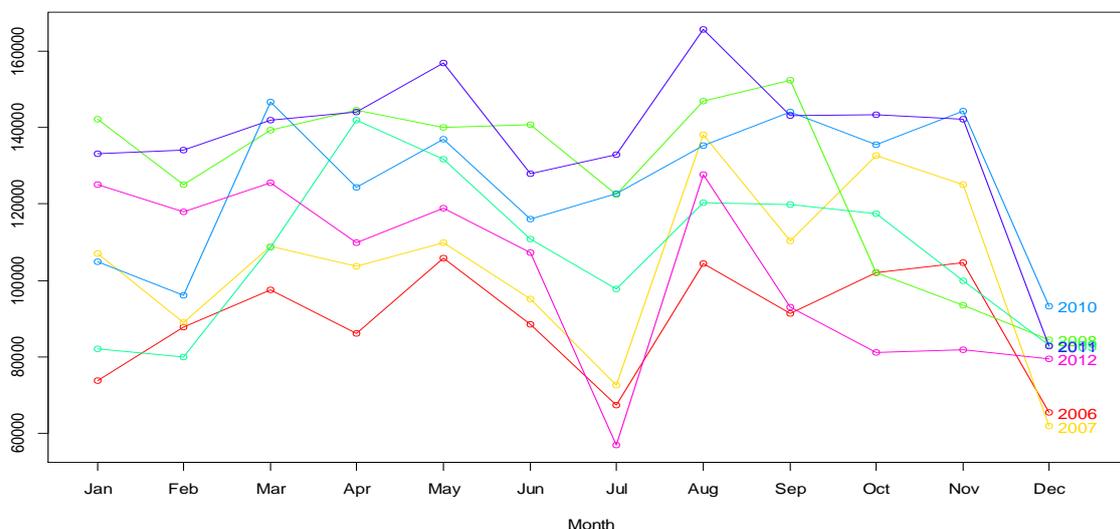


FIGURA 4 - Gráfico sazonal das vendas de motocicletas.

Para complementar foram ajustados aos dados modelos menos sofisticados, que são: a previsão ingênua, previsão ingênua sazonal por média aritmética. A previsão ingênua considera o resultado do período anterior (regular ou sazonal) como estimativa para o período seguinte. Espera-se que os modelos auto-regressivos e de suavização exponencial produzam resultados melhores no que tange a precisão e acurácia das estimativas. Neste sentido comparam-se as duas medidas, MAPE e U-Theil, com objetivo de seleção do melhor modelo (Tabela 4). Estas comparações são realizadas “dentro da amostra”, confrontando-se os valores observados com os preditos pelo modelo e também “fora da amostra”, por meio das previsões para o primeiro semestre de 2013 em relação aos reais valores de vendas neste período.

Analisando-se os resultados da Tabela 4, verificam-se que os dois modelos, SARIMA e ETS, tem indicadores mais favoráveis, que os métodos de previsão ingênua e média aritmética. Pontualmente o SARIMA apresenta indicadores melhores nas previsões e o ETS nas predições. Todavia, com estes resultados, não se pode afirmar que um modelo é melhor que o outro. O ETS tem a vantagem adicional de ser de formulação teórica mais simples. Por outro lado o SARIMA é mais parcimonioso, apresentando um menor número de parâmetros.

TABELA 4 - Medidas dos erros de previsão

	MAPE		U-Theil
	Dentro da amostra	Fora da amostra	
SARIMA	11,50	8,38	0,559
ETS (A,N,A)	10,36	8,58	0,567
Previsão ingênua	18,87	18,43	1,579
Previsão ingênua sazonal	22,06	20,46	1,245
Média aritmética	21,11	19,65	1,219

Em seguida apresentam-se resultados referentes à combinação de previsões dos modelos SARIMA e ETS. A combinação foi feita por meio do critério de variância mínima, com um valor de ponderação $w = 0,084$ e com um peso maior para as previsões do modelo ETS. Os valores de MAPE são iguais a 10,32 (“dentro da amostra”) e 8,56 (“fora da amostra”), ligeiramente melhores que os resultados dos modelos individuais.

A Figura 5 traz os gráficos de predições e previsões para as vendas de motocicletas. Pode-se perceber que os dois modelos trazem resultados similares e a combinação permite um refinamento sensível dos valores das previsões. Estes resultados permitem a compreensão do potencial da combinação de previsões, indo além dos modelos aqui apresentados.

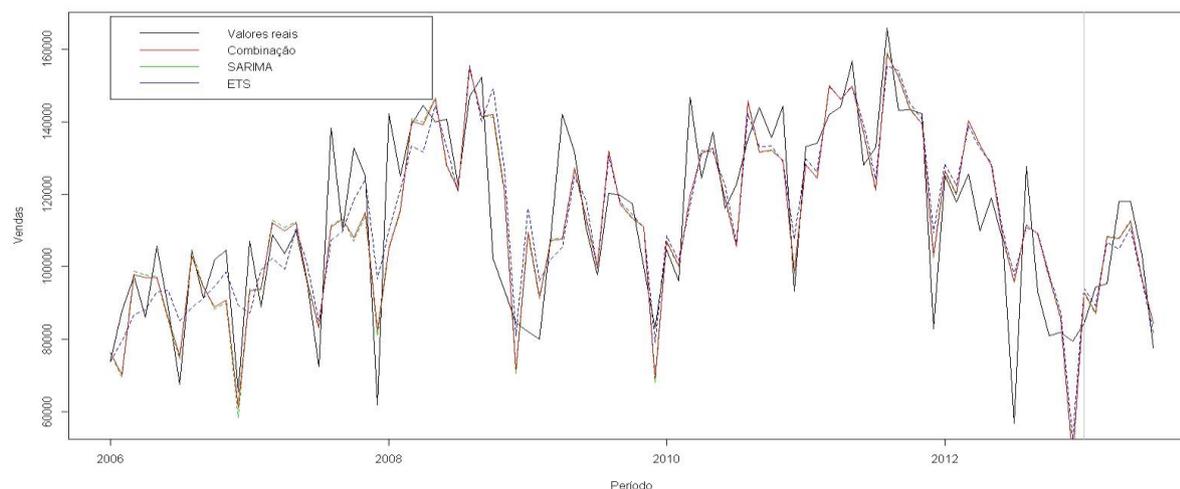


FIGURA 5 - Gráfico da série temporal das vendas de motocicletas e dos valores ajustados com os modelos SARIMA, ETS (A,N,A) e combinação destes modelos.

Os resultados apresentados concordam quanto à sazonalidade com o trabalho de Walter *et al.* (2013), que aplicaram a uma série menor, um modelo autoregressivo de médias móveis para a previsão de vendas de motocicletas. Também vão de encontro aos resultados de Puthran *et al.* (2014), que analisou a acurácia das previsões resultantes de modelos SARIMA e de Suavização Exponencial aplicados à demanda de motocicletas na Índia. Assim, como neste artigo, os dois modelos produzem resultados similares.

Como este trabalho não se encerra aqui, modelos causais também devem ser avaliados, com objetivo de procurar variáveis explicativas para a demanda de motocicletas, como o PIB (Produto Interno Bruto) e incentivos fiscais, por exemplo. A combinação de previsões por meio de séries temporais e modelos causais pode resultar em uma alternativa viável e importantes tanto para o problema proposto, como para outros fenômenos objetos de pesquisa na engenharia e gestão de transportes. Do mesmo modo, características regionais podem influenciar no modelo, assim estes modelos podem ser aplicados a séries específicas de estados ou municípios.

Com este objetivo, a combinação de modelos causais e temporais, podem ser identificadas razões que levam à opção pelo uso da motocicleta, e incluídas no modelo. Para Silva, Cardoso e Santos (2011) a rapidez e agilidade na locomoção além da facilidade de aquisição e manutenção são apontadas como motivos de escolha pela motocicleta. A contagem de fluxo é também uma variável importante a ser incluída em modelos locais. É possível que haja concentração do modal de motocicletas em determinadas vias e rotas, que podem representar outra variável dependente.

5. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Neste artigo foram analisados modelos de previsão de curto prazo, baseados na metodologia Box e Jenkins, suavização exponencial simples e a combinação destes com objetivo de aproximar uma função para a demanda de motocicletas no país. Por meio da metodologia Box & Jenkins, um modelo SARIMA foi aproximado. Já para a suavização exponencial, um modelo ETS (A,N,A), considerando o erro aditivo (A), sem tendência (N), e com sazonalidade aditiva (A) se mostrou uma alternativa viável. As previsões dos dois modelos foram combinadas por meio do critério de variância mínima. Tanto os modelos individuais como a combinação das previsões são opções razoáveis para a previsão da demanda. A combinação permite um refinamento dos valores das previsões e os resultados permitem a compreensão do potencial desta abordagem. Ressalta-se que, no que tange ao problema, analisar o mercado de vendas de motocicletas é essencial, pois o aumento deste modal de transporte pode estar associado a constantes e graves problemas de trânsito, tanto nas pequenas e medias cidades, bem como nos grandes centros urbanos, sendo estes fatores motivos de preocupação para o planejamento de transportes no Brasil.

AGRADECIMENTOS

Os autores agradecem a Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC) pelo apoio ao grupo de pesquisa.

REFERÊNCIAS

ABRACICLO – Associação Brasileira dos Fabricantes de Motocicletas, Ciclomotores, Motonetas Bicletas e Similares. Dados do setor - Motocicletas – Vendas. Disponível em: < <http://www.abraciclo.org.br/dados-do-setor> >. Acesso em 19 de janeiro de 2014.

ABRACICLO. Dados do setor - Motocicletas - 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 04 de março de 2011.

ABRAMET. Associação Brasileira de Medicina de Tráfego. **Acidentes de trânsito no Brasil: um atlas de sua distribuição**. Disponível em: [http: <www.abramet.org.br>](http://www.abramet.org.br). Acesso em 10 de Janeiro de 2007.

BATES, J. M.; GRANGER, C. W. J. The combination of forecasts. **Operational Research Quarterly**, v. 20, n. 4, p. 451-468, 1969.

DENATRAN. Departamento Nacional de Trânsito. **Estatísticas da frota de veículos no Brasil**. Disponível em: [http: <www.denatran.gov.br>](http://www.denatran.gov.br). Acesso em 07 de Janeiro de 2010.

EHLERS, R. S. (2009) Análise de Séries Temporais. Disponível em: < <http://www.icmc.usp.br/~ehlers/stemp/stemp.pdf> >. Acesso em: 08 de março de 2015.

FENABRAVE: Federação Nacional da Distribuição de Veículos Automotores. **Balanco Semestral 2009 do Setor da Distribuição de Veículos Automotores no Brasil**. Set. 2009. Disponível em: < http://www.fenabreve.org.br/principal/pub/anexos/20100526094728Anuario_2009BR.pdf >. Acesso em: 09 de junho de 2011.

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

GUARNIERI, J. P.; SOUZA, A. M.; ALMEIDA, S. G.; SOUZA, F. M.; OLIVEIRA, J. N. D. 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, Salvador. Anais... Salvador/BA, 2009.

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

HIBON, M.; EVGENIOU, T. **To combine or not to combine: selecting among forecasts and their combinations**. *International Journal of Forecasting*, v. 21, p. 15-24, 2005.

HYNDMANN, R. J.; KOEHLER, A. B.; ORD, J. K.; SNYDER, R. D.; GROSE, S. A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods. **International Journal of Forecasting**, v.18, n. 3, p. 439 – 454, 2002

HYNDMANN, 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.

IPEA - Instituto de Pesquisa Econômica e Aplicada. (2011). Infraestrutura Social e Urbana no Brasil subsídios para uma agenda de pesquisa e formulação de políticas públicas - A mobilidade urbana no Brasil. Disponível em: <http://www.energiaeambiente.org.br/arquivos/files/comunicadoipea.pdf>. Acesso em 22 de outubro de 2014.

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

MAKRIDAKIS, S.; HIBON, M. The M3-Competition: results, conclusions and implications. **International Journal of Forecasting**, v. 16, n. 4, p. 451- 476, 2000.

MARTINS, Vera Lúcia Milani; WERNER, Liane. Comparison of individual forecasts and their combinations: a study with industrial series. **Produção**, v. 24, n.3, p. 618 - 627, 2013.

MORETTIN, P.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Blucher, 2004. 535p.

OLIVEIRA, A. M. B.; SOBRINHO, M. J. V. M. Previsão de preço de venda da uva Itália e da manga Tommy produzidas no vale do São Francisco via análise de séries temporais: um estudo de caso. **In:** ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 29, 2009, Salvador. Anais... Salvador/BA, 2009.

PUTHRAN, D.; SHIVAPRASAD, H.C.; KUMAR, K.S.K.; MANJUNATH, M. Comparing SARIMA and Holt-Winters' forecasting accuracy with respect to Indian motorcycle industry. **Transactions on Engineering and Sciences**, v.2, n. 5, p. 25 – 28, 2014.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2014. Disponível em: <<http://www.R-project.org>>. Acesso em: 20 jan. 2014.

SILVA, E.R; CARDOSO, B.C.; SANTOS, M.P.S. O aumento da taxa de motorização de motocicletas no Brasil. **Revista Brasileira de Administração Científica**, v.2, n.2, p. 49 – 63, 2011.

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

TUBINO, D. F. **Planejamento e Controle da Produção**. São Paulo: Atlas, 2007.

FORMIGONI, C. W. O. M.; HENNING, E.; MORO, G.; SAMOHYL, W. R. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta**, v.11, n.1, p. 77-88, 2013.