

# Previsão de vendas para um modelo de automóvel popular com a metodologia Box e Jenkins

*Olga Maria Formigoni Carvalho Walter (PPGEP/UFSC)*

*Elisa Henning (UDESC)*

*Rodrigo Gabriel de Miranda (PPGEP/UFSC)*

*Robert Wayne Samohyl (PPGEP/UFSC)*

## Resumo

*Em virtude da variação da demanda que o mercado automobilístico está exposto, como a crise econômica mundial de 2008 que afetou o setor, intensificou-se a necessidade de realizarem-se previsões de vendas de maior assertividade que garantam o andamento das decisões estratégicas das montadoras de automóveis. O objetivo principal deste artigo é propor um modelo de previsão de vendas de curto prazo, baseado na metodologia Box e Jenkins, considerando a categoria de automóveis populares. As previsões foram realizadas para seis períodos, compreendendo março a agosto de 2010. Quando comparado com o mesmo período de 6 meses do ano de 2009, a previsão gerada pelo modelo é 9,3% menor.*

*Palavra chave: Previsão de vendas, séries temporais, Box-Jenkins, carro popular.*

## 1 Introdução

A previsão de demanda tem um papel de extrema importância para todos os setores de uma organização, pois possibilita definir antecipadamente um conjunto de ações e intenções, através de decisões estratégicas adequadamente planejadas. É, portanto uma atividade fundamental em qualquer segmento de atuação, permitindo detectar tendências de mercado, que contribuem para o planejamento estratégico da empresa e na solução de problemas imediatos (PRATA et al., 2009)

O uso de modelos de previsão diminui a incerteza associada a decisões gerenciais e através deles as organizações podem obter progressos tanto na área produtiva como nas outras áreas funcionais, mediante a sincronização entre nível de vendas e de capacidade produtiva.

Neste sentido, métodos de previsão que apresentem informações precisas são de fato, técnicas gerenciais estratégicas que auxiliam o setor industrial na tomada de decisões. As empresas podem alocar melhor recursos financeiros, gerando meios para adaptarem-se as possíveis flutuações da demanda. Como exemplo está à crise econômica mundial de 2008 e seus reflexos no setor automotivo, onde praticamente todas as montadoras foram atingidas pela desaceleração da economia. A redução de crédito para os consumidores resultou em queda nas vendas, afetando diretamente as montadoras, que diante da crise estavam com seus pátios de estoques superlotados.

O Brasil destaca-se tanto na produção quanto no consumo de automóveis. De acordo com dados da Federação Nacional da Distribuição de Veículos Automotores (FENABRAVE), no período de 2005 a 2009, foi crescente a quantidade de emplacamentos de automóveis no Brasil. De 2005 para 2009 houve um aumento de 44,8% na quantidade de automóveis emplacados.

Depois de o setor automobilístico ter sido profundamente atingido pela crise econômica mundial no final de 2008, as medidas de isenção do Imposto sobre Produtos Industrializados (IPI) foram fundamentais para manter o ritmo de vendas no segmento ao longo de 2009. A queda de 26%, em novembro e dezembro de 2008, em relação ao mesmo período do ano anterior, foi sinalização para que o governo implementasse as medidas fiscais que foram fundamentais para estimular o setor ao longo do ano.

Em 2009, período no qual o estímulo fiscal vigorou, as vendas de automóveis e veículos comerciais leves alcançaram um patamar histórico, alcançando uma alta de 5,49% se comparado ao mesmo período do ano anterior. No momento, mesmo sem a isenção fiscal, a indústria segue aquecida, com excelentes indicadores de altos níveis de produção para 2010 (RIGOTTO, 2010).

Este trabalho tem como objetivo analisar um modelo adequado de previsão de vendas de um automóvel popular

Novembro de 2010, Santiago, Chile

utilizando a metodologia Box e Jenkins, procurando verificar qual modelo apresenta melhor aderência a série estudada, diante das constantes variações de demanda que este mercado está exposto.

O trabalho está estruturado da seguinte maneira: na seção 2 e 3 estão os conceitos de previsão de séries temporais e a metodologia Box e Jenkins, na seção 4 a apresentação dos dados e procedimentos metodológicos, na seção 5 os resultados e análise destes. Finalizando, na seção 6 estão as conclusões e considerações finais.

## 2 Previsão de 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).

Segundo 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 dessas componentes (SOUZA et al., 2008).

## 3 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). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em várias combinações de modelos (WERNER e RIBEIRO, 2003; COELHO e SAMOYL, 2007; GUARNIERI et al., 2009).

Os modelos: AR(p), onde a série é descrita por seus valores passados regredidos e pelo ruído aleatório; MA(q), que explora a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores e; ARMA(p, q) que apresentam processos mistos AR(p) e MA(q), 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 et al., 2001; GUJARATI, 2006). Entretanto, quando a série é não-estacionária, além dos modelos citados, é utilizada a componente de integração I(d), resultando no modelo ARIMA(p,q,d). Depois de calcular a diferença entre os valores subjacentes da série  $d$  vezes, é possível torná-la estacionária, de modo que ofereça uma base válida para a previsão (OLIVEIRA e 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 e diferenciação ARIMA (parte não sazonal) e as maiúsculas representam a ordem dos modelos e diferenciação sazonal (MAKRIDAKIS et al., 1998; GUARNIERI et al., 2009). Mais detalhes e demonstrações dos modelos abordados nesta seção podem ser encontrados em Makridakis et al. (1998), Hanke et al. (2001), Moretin e Tolo (2004) e em Gujarati (2006).

### 3.1 Etapas da metodologia Box e Jenkins

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 melhor 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 autoregressivo integrado de médias móveis ARIMA (p,d,q), ou ainda, por um modelo ARIMA (p,d,q) sazonal.

A Tabela 1 apresenta alguns padrões teóricos para as funções de autocorrelação (FAC) e autocorrelação parcial (FACP) sugeridos por Gujarati (2006), com a finalidade de auxiliar a identificação e estimação do modelo.

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.

Tabela 1: Padrões teóricos das funções de autocorrelação (FAC) e autocorrelação parcial (FACP)

Modelo	Padrão típico FAC	Padrão típico FACP
AR(p)	Declina exponencialmente e/ou com um padrão de onda senóide amortecida	Apresentam picos significativos até $p$ defasagens
MA(q)	Apresentam picos significativos até $q$ defasagens	Declina exponencialmente
ARMA(p,q)	Diminui exponencialmente	Diminui exponencialmente

Fonte: GUJARATI (2006)

A Figura 1 representa as etapas da construção do modelo de previsão via metodologia Box e Jenkins proposto por Makridakis et al. (1998) que é composto por três etapas, que o autor caracteriza por fases.

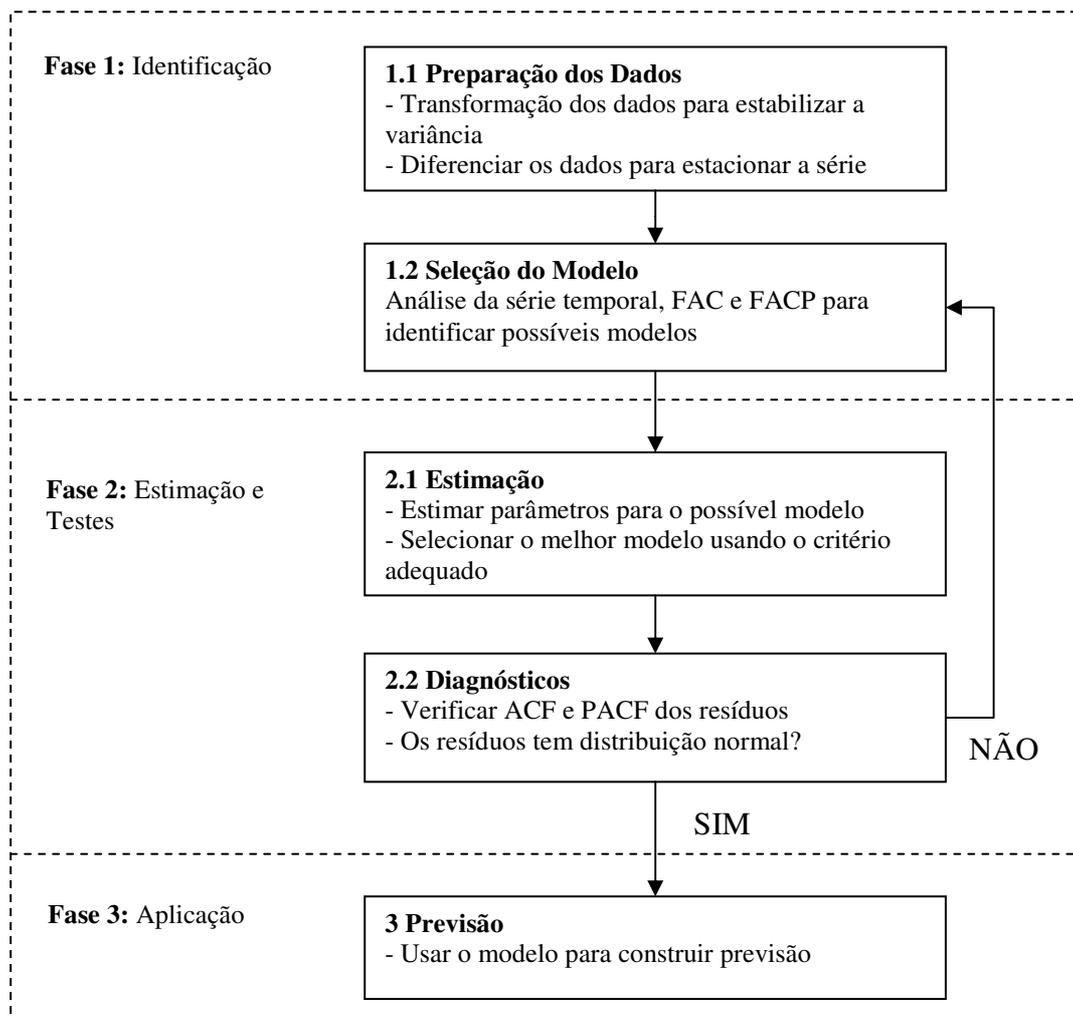


Figura 1: Etapas da construção do modelo de previsão via metodologia Box e Jenkins

Fonte: Adaptado de Makridakis et al. (1998)

A fase inicial de Identificação, é a etapa na qual é realizada a preparação dos dados, onde estes são transformados para estabilizar a variância e diferenciados para que se tornem estacionários. 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.

Na fase 2, definida como Estimção e Testes, são estimados os parâmetros do modelo mais adequado. 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) é avançada para a fase 3 de Aplicação, onde é realizada a previsão baseada no modelo selecionado, caso contrário, retorna-se para a segunda parte da fase 1 e repete-se todo o ciclo.

### 3.2 Critérios de avaliação do modelo

Existem vários critérios que são utilizados para avaliação de modelos concorrentes e avaliar a qualidade da previsão gerada pelo modelo, porém nesta seção serão descritos apenas os critérios utilizados neste trabalho para avaliar como o modelo escolhido se ajusta aos dados. Considerou-se para a seleção do melhor modelo ajustado, o critério de avaliação baseado no *Mean Absolute Percentual Error* (MAPE), erro percentual absoluto médio e o indicador de *Akaike Information Criteria* (AIC), critério de informação de Akaike.

O erro percentual absoluto médio, representado pela equação  $\frac{1}{n} \sum_{t=1}^{i=n} |e_t/O_t|$  é uma medida de erro de previsão que informa em quanto está se errando em termos percentuais na previsão. Onde  $e_t$  representa a diferença entre o valor previsto e o valor observado,  $O_t$  o valor observado e  $n$  o número de elementos previstos (SOUZA et al., 2008).

O critério de informação de Akaike (AIC) impõem uma penalidade para o acréscimo de um número cada vez maior de parâmetros ao modelo e é definido como  $AIC = -2 \log(L) + 2(p + q + P + Q + 1)$ . Onde  $L$  é a função de verossimilhança do modelo ARIMA ajustado e  $(p, q, P, Q)$  o número de parâmetros. 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 menor perda de informação em relação à realidade (GUJARATI, 2006).

## 4 Material e métodos

Os dados correspondem a registros mensais de vendas de um automóvel popular, observados durante o período de janeiro/2005 a fevereiro/2010, compreendendo 62 observações (Tabela 2).

Tabela 2: Série de vendas mensal de automóvel popular

Mês/Ano	2005	2006	2007	2008	2009	2010
Janeiro	7515	10341	8026	10908	11972	9845
Fevereiro	6990	9200	7948	10231	11354	10640
Março	10005	10541	10206	12175	15084	-
Abril	10731	9380	10448	12862	15301	-
Maió	11079	10487	12241	13082	15897	-
Junho	11439	10405	11371	12790	15552	-
Julho	11503	9217	12837	13024	15502	-
Agosto	12260	10300	11975	12007	14543	-
Setembro	9174	9459	9580	13646	15039	-
Outubro	10515	8266	12526	12331	16701	-
Novembro	10308	8801	13282	10559	15015	-
Dezembro	9729	6305	9634	8157	11219	-

Fonte: Assistência técnica da montadora

Os dados apresentados servirão para realizar a aplicação do modelo de previsão, descritos na seção 3. Como ferramenta de apoio, será utilizado o ambiente GNU R (R *Development Core Team*, 2009) e o pacote *forecast* (HYNDMANN, 2008). A metodologia utilizada no pacote *forecast* pode é detalhada em Hyndman e Khandakar (2008). Para escolher o modelo serão utilizados como critério de análise o erro absoluto percentual médio (MAPE) e o critério AIC.

## 5 Análise dos resultados

A aplicação do modelo será realizada de acordo com as etapas da metodologia Box e Jenkins propostas por Makridakis et al. (1998) na seção 3.1 na Figura 1. Estas etapas foram utilizadas para encontrar o modelo mais parcimonioso que represente o comportamento da série de automóveis em estudo, a fim de obter-se previsões com os menores erros possíveis.

### 5.1 Fase 1 - Identificação

#### 5.1.1 Preparação dos dados

Na Figura 2 é apresentado o gráfico da série temporal original. Através dele pode-se perceber que a série não é estacionária, apresentando tendência de crescimento de vendas ao longo dos anos. Alguns “picos” de redução de vendas são notados no final dos anos de 2006 e 2008. Como a análise visual do gráfico da série original não é conclusiva, recorreu-se a análise de outros gráficos como: um gráfico sazonal (Figura 3) e os gráficos da função de autocorrelação e autocorrelação parcial da série original (Figura 4) que auxiliam na verificação da estacionariedade e sazonalidade da série, contribuindo para a definição de um modelo mais apropriado.

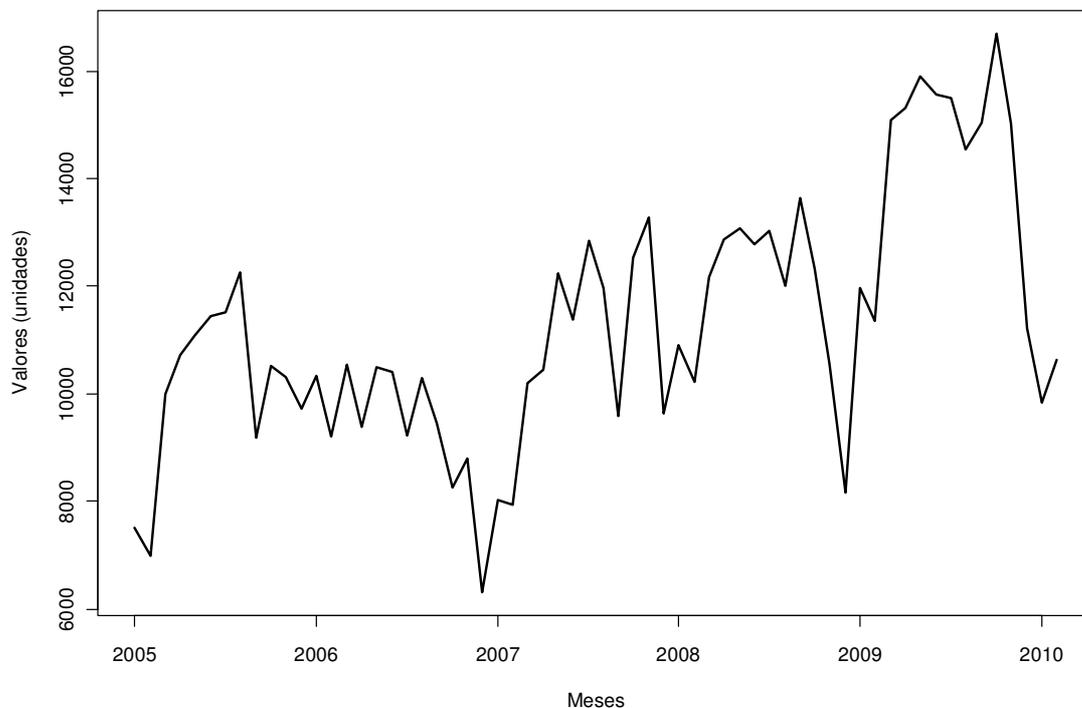


Figura 2: Representação da série de vendas mensais de um automóvel popular

Na Figura 3 visualiza-se o gráfico sazonal. Neste, cada linha corresponde a um ano e é possível visualizar as unidades vendidas em cada mês. Pelo comportamento dos dados, constatou-se que existe sazonalidade na série. Visualiza-se a queda nas vendas no final dos anos, com destaque isolados nos meses de outubro de 2006 e setembro de 2007 e 2008, diferente do comportamento dos demais anos. Do mesmo modo, em janeiro e fevereiro de 2010, há um acréscimo nas vendas.

Além da observação dos correlogramas para comprovar a estacionariedade da série, aplicou-se o teste de hipóteses de Dickey Fuller onde se confirmou a presença de não-estacionariedade na série, onde a hipótese nula ( $H_0$ : a série é não-estacionária;  $p$ -valor=0,1117), não foi rejeitada.

O gráfico da função de autocorrelação (Figura 4a) ratifica a não-estacionariedade da série. Para remover a

Novembro de 2010, Santiago, Chile

estacionariedade da série aplicou-se a primeira diferença (SAMOHYL, 2009). Esta foi suficiente para estacionar a série, conforme o gráfico da função de autocorrelação da série diferenciada (Figura 5a).

### 5.1.2 Seleção do modelo

Os gráficos da função de autocorrelação e autocorrelação parcial (Figura 5a e 5b) identificam apenas a componente AR sazonal, sem evidenciar as componentes AR e/ou MA, mas não as descartando. Uma das desvantagens da metodologia Box e Jenkins (Morettin e Tolo, 2004) é que mais de um modelo pode ser adequado para a mesma série de dados. Assim optou-se por um procedimento automático de escolha de modelos, pacote *forecast* (HYNDMANN, 2008). Como complementação comparou-se com outros modelos possíveis identificados na análise gráfica.

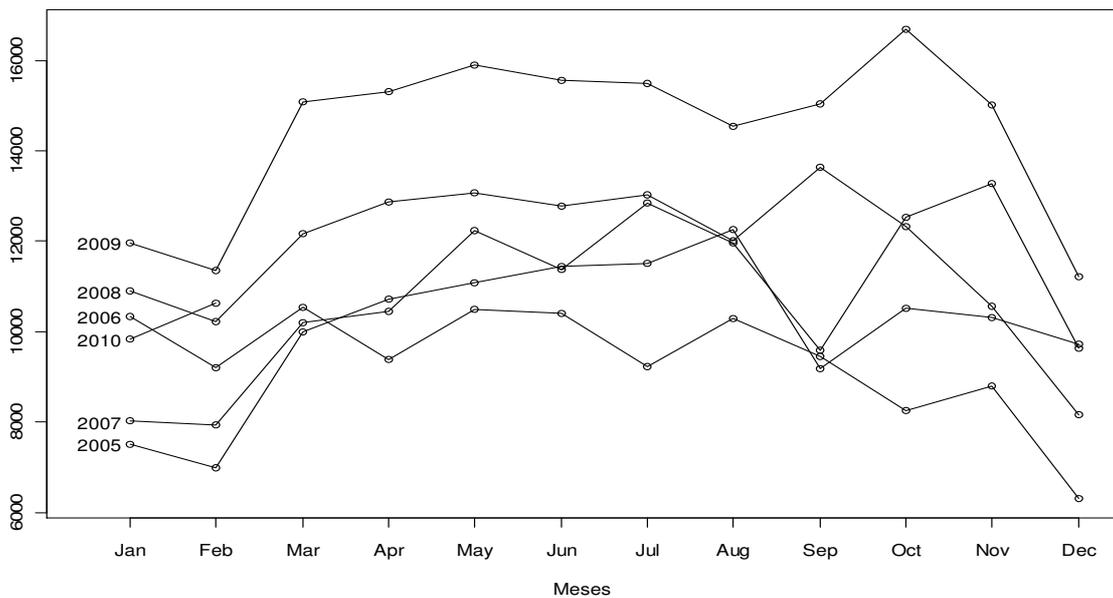


Figura 3: Gráfico das vendas por mês

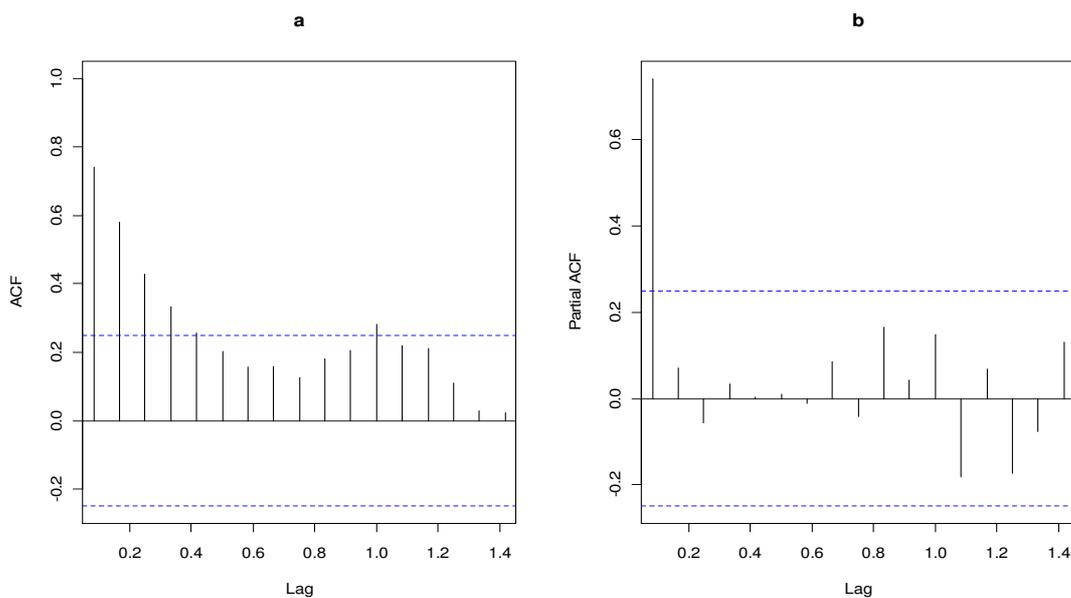


Figura 4: Gráficos da função de autocorrelação (a) e autocorrelação parcial (b)

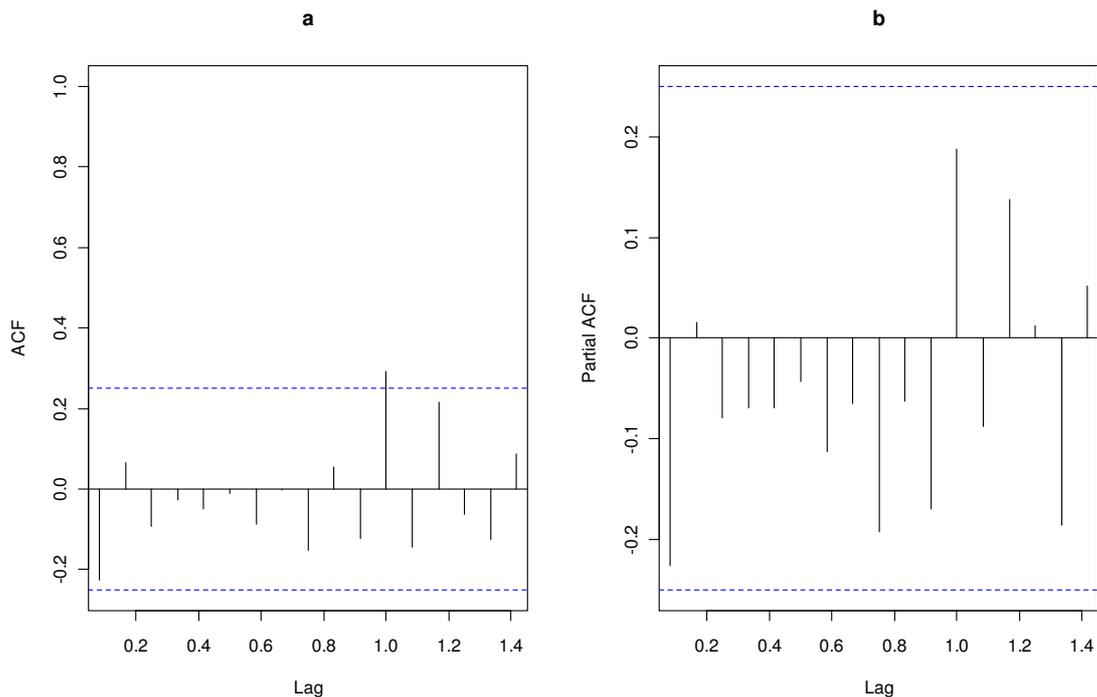


Figura 5: Gráficos da função de autocorrelação (a) e autocorrelação parcial (b) da série diferenciada

## 5.2 Fase 2 - Estimação e Testes

### 5.2.1 Estimação

Para a estimação dos parâmetros utilizou-se o ambiente GNU R com o pacote *forecast*. Os valores iniciais são definidos através da minimização da soma dos quadrados condicionais e em seguida os parâmetros são estimados pelo método da máxima verossimilhança.

O pacote *forecast* retornou um modelo SARIMA (1,1,1)(2,0,0)<sub>12</sub> e, este foi comparado mediante o critério de Akaike (AIC) e o MAPE com outros modelos. Como as componentes AR e MA da parte não sazonal não ficam evidentes nos correlogramas, modelos sem estas partes foram considerados na análise (Tabela 3). Analisando o AIC e MAPE o modelo SARIMA (0,1,0) (1,0,0)<sub>12</sub> apresenta os menores valores de MAPE e AIC. Todavia na análise de resíduos, estes apresentam autocorrelação, não sendo este modelo adequado para previsões. Deste modo partiu-se para o segundo modelo, SARIMA (1,1,1) (2,0,0)<sub>12</sub> escolhido pelo R, para análise. A Tabela 4 apresenta os parâmetros estimados e erro padrão do modelo SARIMA (1,1,0)(2,0,0)<sub>12</sub>.

Tabela 3: Critério de AIC e MAPE para os modelos estimados

Modelo	AIC	MAPE
SARIMA (1,1,1) (2,0,0) <sub>12</sub>	1057,47	8,42
SARIMA (1,1,1) (1,0,0) <sub>12</sub>	1068,58	9,95
SARIMA (0,1,0) (1,0,0) <sub>12</sub>	855,88	7,62
SARIMA (0,1,0) (2,0,0) <sub>12</sub>	1060,41	9,15
SARIMA (1,1,0) (2,0,0) <sub>12</sub>	1058,93	8,67

Fonte: Os autores

Tabela 4: Coeficientes do modelo SARIMA (1,1,1)(2,0,0)<sub>12</sub> e respectivos erros-padrão

Coefficiente	Estimativa	Erro padrão
$\phi_1$	0,6357	0,1632
$\theta_1$	-0,9247	0,0780
$\Phi_1$	0,1812	0,1023
$\Phi_2$	0,5324	0,1194

Fonte: Os autores

### 5.2.2 Diagnóstico

É importante analisar os resíduos do modelo quanto à normalidade e também verificar se possuem autocorrelação. Observa-se através da Figura 6a e 6b que os resíduos são não-correlacionados, uma vez que, todos os lags encontram-se dentro dos limites de 95% confiança

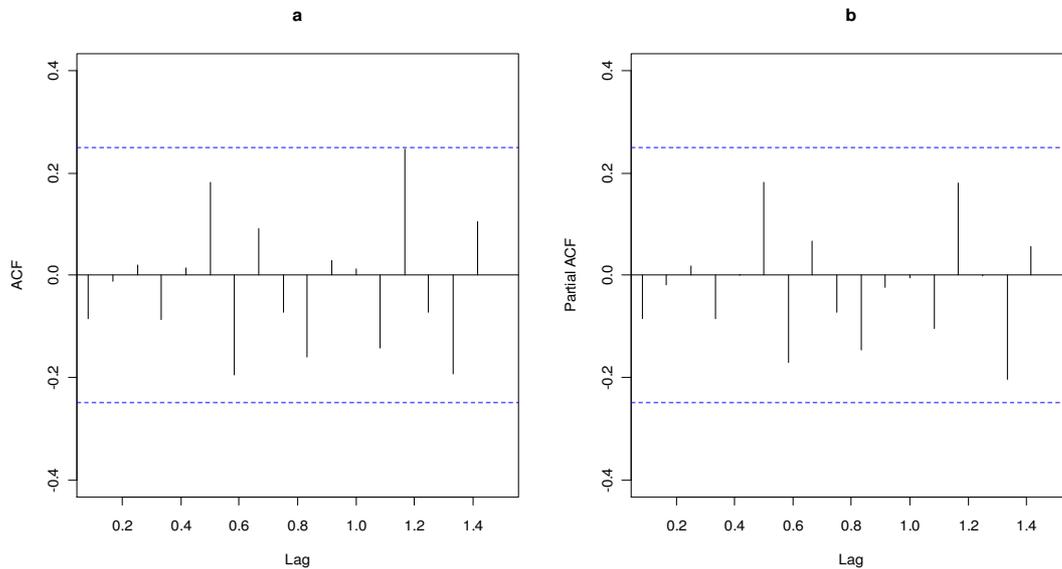


Figura 6: Gráfico da função de autocorrelação (a) e autocorrelação parcial (b) dos resíduos

Através do, histograma (Figura 7a) e gráfico de probabilidade normal (Figura 7b), verifica-se que os resíduos do modelo tem distribuição normal (p-valor=0,5745).

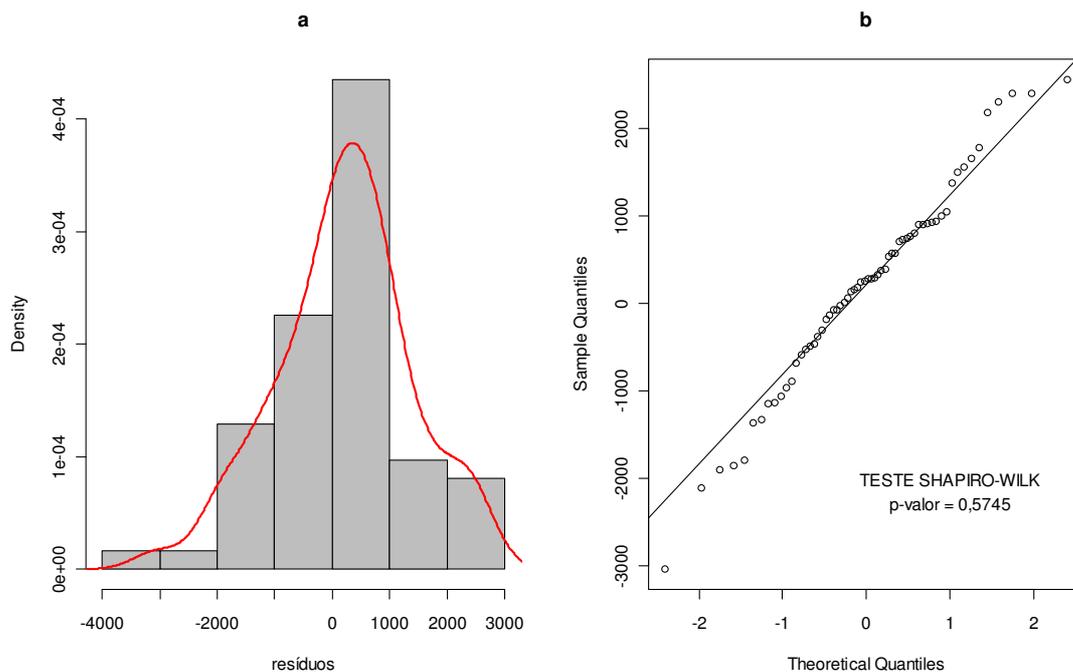


Figura 7: Histograma e gráfico de probabilidade normal dos resíduos

### 5.3 Fase 3 - Previsão

De acordo com a análise dos resíduos, o modelo SARIMA (1,1,1)(2,0,0)<sub>12</sub> pode então ser utilizado para previsões. O modelo de previsão com seus parâmetros estimados pode ser descrito por:

$$(1 - 0,6357B)(1 - 0,1812B^{12} - 0,5324B^{24})(1 - B)Y_t = (1 + 0,9247B)a_t$$

Na Tabela 5 estão as previsões pontuais e intervalos de 80 e 95% de previsão para um período de seis meses (março a agosto de 2010).

Tabela 5: Estimativas pontuais e com intervalo de 80 e 95% de confiança

Período	Prev. Pontual	LI 80%	LS 80%	LI 95%	LS 95%
Mar 2010	12952,19	11425,47	14478,91	10617,28	15287,10
Abr 2010	13750,28	11860,94	15639,63	10860,78	16639,79
Mai 2010	14232,33	12163,64	16301,03	11068,54	17396,13
Jun 2010	14182,28	12009,11	16355,46	10858,71	17505,86
Jul 2010	14407,59	12165,87	16649,30	10979,17	17836,00
Ago 2010	13764,10	11472,70	16055,49	10259,71	17268,48

Fonte: Os autores

Na Figura 7 tem-se um gráfico com a série original (em preto), valores ajustados (em azul) e previsões pontuais e intervalares para seis meses adiante. A faixa em laranja corresponde ao intervalo de 80% e a amarela de 95%.

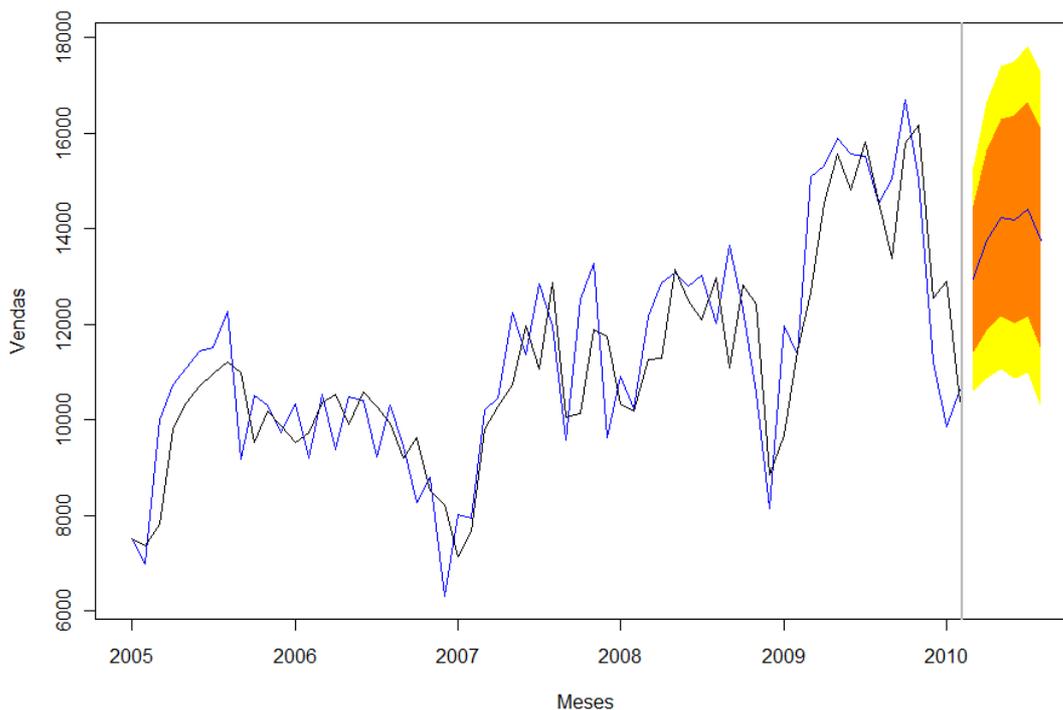


Figura 7: Gráfico da série original (em preto), valores ajustados (azul) e previsões (área sombreada)

## 6 Conclusão e considerações finais

Os modelos de séries temporais baseados na metodologia Box e Jenkins podem ser uma boa alternativa para a previsão de vendas do produto proposto. Entre os modelos ajustados o SARIMA (1,1,0)(2,0,0)<sub>12</sub>, apresentou os menores valores para AIC e MAPE, e os resíduos se comportam como um ruído branco.

Novembro de 2010, Santiago, Chile

Vale ressaltar que, como 42% da quantidade de observações da série utilizadas no estudo contava com a medida fiscal de isenção de IPI, recomenda-se fazer um nova previsão com novas observações após o retorno da cobrança de IPI para que verifique se esta isenção fiscal faz com que a série comporte-se de outra maneira, o que possibilita gerar um modelo de previsão diferente do proposto neste trabalho.

As previsões de março a agosto de 2010 indicam uma queda de 9,3% nas vendas se compararmos com o mesmo período de 2009. Isto até pode ocorrer devido ao final dos incentivos fiscais de IPI.

Como sugestão para trabalhos futuros está a análise de outros modelos aplicados à série, como de suavização exponencial, além dos modelos de regressão múltipla e dinâmica, onde outras variáveis independentes são incorporadas. Recomenda-se também efetuar a análise dos erros de previsão dentro e fora da amostra, de modo à melhor avaliar os resultados alcançados.

### **Referências Bibliográficas**

COELHO, L. C.; SAMOBYL, R. W. Avaliação de modelos de previsão para a quantidade de automóveis no estado de Santa Catarina. XIV SIMPEP. 2007.

FENABRAVE: Federação Nacional da Distribuição de Veículos Automotores. Balanço 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](http://www.fenabreve.org.br/principal/pub/anexos/20100526094728Anuario_2009BR.pdf)>. Acesso em: 27/05/2010.

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. XXIX Encontro Nacional De Engenharia De Produção, ENEGEP. Salvador/BA, 2009.

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

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.

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

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. XXIX Encontro Nacional De Engenharia De Produção, ENEGEP. Salvador/BA, 2009.

PRATA, M. S.; RUSSO, S. L.; SIMON, V. H.; CAMARGO, M. E. Aplicação do controle estatístico de qualidade na variável dt no processo de perfilagem de um poço de petróleo. XXIX Encontro Nacional de Engenharia de Produção, ENEGEP. Salvador/BA, 2009.

RIGOTTO, G. As lições da redução do IPI. Federação Nacional da Distribuição de Veículos Automotores. Disponível em: <[http://www.fenabreve.com.br/principal/pub/anexos/20100115065938artigo\\_germano\\_rigotto.pdf](http://www.fenabreve.com.br/principal/pub/anexos/20100115065938artigo_germano_rigotto.pdf)>. Acesso em 17/06/2010.

SOUZA, G. P.; SAMOBYL, 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, 2007.190p.

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