

MODELAGEM DA EXPORTAÇÃO BRASILEIRA DE AUTOMÓVEIS

Amanda Cabalini Zucoloto

Universidade Federal de São João del Rei
amandazucoloto@hotmail.com

Luciane Teixeira Passos Giarola

Universidade Federal de São João del Rei
luciane@ufsj.edu.br

Rejane Correa da Rocha

Universidade Federal de São João del Rei
rejane@ufsj.edu.br

RESUMO

os últimos cinco anos a indústria automotiva brasileira passou por momentos cíclicos, gerando dificuldades no planejamento de ações. Sabe-se que a exportação é o caminho mais eficaz para garantir o futuro das empresas automobilísticas em um ambiente globalizado, além de contribuir para a geração de renda e emprego e promoção do desenvolvimento econômico do país. Assim, o presente artigo teve o objetivo de analisar a exportação brasileira de automóveis de Janeiro de 2009 a Abril de 2018 e obter, por meio de séries temporais, um modelo estatístico capaz de representar o comportamento da série, e que permitisse prever os valores futuros da exportação. Por meio do Critério de Informação de Akaike (AIC) foram selecionados seis modelos da classe SARIMA (Sazonal Autorregressivo Integrado e de Médias Móveis), com e sem intervenção, cujos resíduos eram ruído branco. Tomou-se Erro Percentual Absoluto Médio (MAPE) para escolha do modelo de previsão. Verificou-se que a metodologia proposta foi útil para descrever o comportamento da exportação brasileira de automóveis, sendo o modelo SARIMA(0, 1, 1)(1, 0, 0)₁₂ com intervenção em Maio de 2012 o que forneceu previsões mais satisfatórias.

ABSTRACT

In the last five years the Brazilian automotive industry has gone through cyclical moments, generating difficulties in the planning of actions. It is known that export is the most effective way to guarantee the future of auto companies in a globalized world, besides contributing to the generation of income and employment and promotion of the economic development of the country. Thus, this paper analyzed the Brazilian automobile exports from January 2009 to April 2018 and obtain, by means of time series, a statistical model which allowed forecasting the future values of the serie. Using the Akaike Information Criterion (AIC), six SARIMA models were selected. For these models, were analyze the statistical significance of the coefficients and if the residuals were white noise. The model that provided the best prediction was chosen by the mean absolute error indicator (MAPE). MAPE is calculated by averaging all absolute percentage errors. The model chosen was the SARIMA (0, 1, 1)(1, 0, 0)₁₂ with intervention in May 2012, due to accurate forecasts and satisfactory statistical results.

Palavras-chave: série temporal, exportação de automóveis, SARIMA, previsão.

1 INTRODUÇÃO

Uma série temporal pode ser definida como um conjunto de observações sequenciadas no tempo e equidistantes entre si, cuja principal peculiaridade é a relação de dependência entre observações vizinhas, denominada autocorrelação serial. Assim, a análise de séries temporais é uma metodologia empregada no estudo de dados com essa natureza e que permite modelar essa estrutura de autocorrelação. Os modelos utilizados possibilitam investigar o mecanismo gerador da série, fazer previsões de valores futuros, procurar periodicidades relevantes ou apenas descrever o comportamento da série (Morettin e Toloi [1]).

Uma suposição frequentemente feita sobre uma série temporal é a de estacionariedade, ou seja, a série apresenta média e variância constantes no tempo e as covariâncias entre as observações dependem apenas da distância entre os tempos e não do próprio tempo. Para modelar séries com essa estrutura de autocorrelação, Box e Jenkins [2] propuseram os modelos paramétricos da classe ARMA (Auto-Regressivos e de Médias Móveis). Porém, a maioria das séries encontradas apresentam algum tipo de não estacionariedade, tal como componentes de tendência e sazonalidade. Nesses casos, é necessário transformar a série antes de aplicar a metodologia. Para tanto, são tomadas diferenças sucessivas até que se obtenha uma série estacionária. Alternativamente, essas componentes podem ser incorporadas na modelagem utilizando-se os modelos ARIMA (Auto-Regressivos Integrados de Médias Móveis) e SARIMA (Auto-Regressivos Integrados de Médias Móveis Sazonal).

A estratégia para a construção dos modelos é baseada em um ciclo iterativo. Primeiramente são analisadas as funções de autocorrelação e autocorrelação parcial a fim de identificar os possíveis parâmetros. Em seguida vem a fase de estimação, na qual os parâmetros identificados são estimados. Finalmente, é feita a análise dos resíduos para verificação de adequacidade. Caso o modelo ajustado não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. Pode ocorrer de se ter mais de um modelo adequado para explicar os dados. Nesse caso, deve-se utilizar algum critério de escolha baseado no número de parâmetros e na variância do modelo.

Essa metodologia pode ser aplicada em diversas áreas do conhecimento. Barbosa et al. [3] utilizaram a metodologia para obter um modelo estatístico que permitisse prever os valores futuros de temperatura média mensal da cidade de Bauru (SP). Tidre, Biase e Silva [4] analisaram o comportamento da série do consumo de energia elétrica na região norte do Brasil, por meio de modelos SARIMA com intervenção. Giarola, Takenaka e Rocha [5] estudaram o consumo de energia elétrica no Centro Federal de Educação Tecnológica de Minas Gerais (CEFET - MG) para avaliar por quanto tempo a produção energética seria capaz de suprir o crescente consumo na instituição, avaliar o potencial de geração e a viabilidade de implantação de um sistema de geração solar fotovoltaico. Santili [6] estudou o comportamento da produção brasileira de caminhões e fez previsões utilizando um modelo ARIMA. Souza [7] analisou a taxa de ocupação hospitalar nos setores denominados Hospital Geral e Pronto Atendimento do Hospital Universitário de Santa Maria para fazer previsão utilizando intervenções. Assim, destaca-se a importância de utilizar estes procedimentos e métodos estatísticos como ferramentas de análise para compreender e enriquecer a investigação científica referente aos mais diversos assuntos, buscando descrever e identificar padrões de comportamento nas séries ao longo dos anos, bem como analisar as relações presentes nas observações.

A metodologia também pode ser utilizada para análise da série temporal referente à exportação brasileira de automóveis. Nesse sentido, este trabalho teve por objetivo o estudo da série histórica da exportação de automóveis brasileiros no período de Janeiro de 2009 a Abril de 2018 e a obtenção de um modelo de previsão, via metodologia Box & Jenkins, que possa ser utilizado para fornecer estimativas futuras para a quantidade de automóveis

exportados. A indústria automotiva passou a atuar no Brasil a partir da década de 50 do século XX, incentivada por programas criados pelos governos da época. Em 1969, ocorreu a primeira exportação de veículos brasileiros. Segundo Micaelo [8], até 1990 as exportações das indústrias automotivas brasileiras possuíam uma baixa representatividade mundial. Entre 1991 e 1995 as exportações cresceram, reflexo de investimentos no setor devido ao Mercosul e ao baixo desempenho do mercado interno. Com a chegada do Plano Real em 1994, o mercado interno se aqueceu e os investimentos foram insuficientes para atender a demanda, gerando déficit externo do setor. Então, foi lançado em 1996 o Regime Automotivo, afim de atrair novas montadoras, modernizar o setor e estabelecer acordos com países do Mercosul. Para Micaelo [8], essa medida surtiu efeito a partir de 1998, provocando o aumento do número de exportações. A partir de 2005, a apreciação cambial brasileira e o dinamismo do mercado interno ocasionaram estagnação e, posteriormente, queda das exportações de veículos até 2010. A redução das exportações também pode ser explicada pela concorrência dos países asiáticos, em particular a China. (Barros e Pedro [9]).

Em setembro de 2013 houve um aumento súbito no número de automóveis brasileiros exportados. Esse crescimento foi influenciado pela desvalorização do real frente ao dólar, de acordo com informação obtida no Portal Brasil [10]. Deve-se também aos acordos com a Argentina, maior importador de automóveis brasileiros, que deixaram de vigorar desde julho de 2013, passando a valer o livre comércio (Martello [11]).

Nos últimos cinco anos a indústria automotiva brasileira passou por momentos cíclicos, gerando dificuldades no planejamento de ações. A desvalorização cambial e a retração da economia brasileira contribuíram para que o Brasil registrasse um saldo positivo nas suas operações de comércio exterior. Em Janeiro de 2017, de acordo com a Associação Nacional dos Fabricantes de Veículos Automotores (Anfavea), o Brasil registrou a melhor marca em exportações desde 2008. Foram vendidos ao exterior 37.189 veículos montados, o que representa uma alta de 56%, comparando com o mesmo mês de 2016 (Fussy [12]).

Ressalta-se que na área automotiva há uma carência de estudos. Salles et al. [13] utilizaram modelos de regressão linear, amortecimento exponencial e modelos SARIMA para verificar a performance de previsões utilizando a série temporal mensal de vendas de automóveis no Brasil no período de Janeiro de 2000 a Agosto de 2009. Os modelos mais adequados foram os da classe SARIMA, pois forneceram os melhores ajustes. O modelo menos adequado foi obtido pelo método de regressão, pois este método não capta o comportamento da tendência e sazonalidade presentes nos dados analisados. Guarnieri et al. [14] através da metodologia de Box & Jenkins estudaram a série mensal produção de automóveis e realizaram previsões para o segundo semestre de 2008 e primeiro semestre de 2009. Verificaram a discrepância provocada pela crise econômica, a partir de Setembro de 2008, entre os valores previstos e os valores reais de produção de automóveis. Salienta-se que não foram encontrados na literatura referências à análise e previsão da série de exportação brasileira de automóveis através da metodologia de Box Jenkins [2]. A importância desse estudo justifica-se na grande relevância do assunto para as empresas, pois, segundo o Ministério das Relações Exteriores [15], a exportação é o caminho mais eficaz para garantir o futuro das mesmas em um ambiente globalizado. Além disso, a atividade exportadora tem também importância estratégica para o Brasil, pois contribui para a geração de renda e emprego, para a entrada das divisas necessárias ao equilíbrio das contas externas e para a promoção do desenvolvimento econômico. Assim, a análise dessa série poderá auxiliar no planejamento de ações e investimentos no setor.

2 MATERIAIS E MÉTODOS

A série proposta é a de exportação brasileira de automóveis, no período de Janeiro de 2009 à Abril de 2018, totalizando 112 observações. O horizonte de previsão contemplou de Novembro de 2017 a Abril de 2018, portanto, os valores reais dos seis últimos meses não foram incluídos na modelagem e sim reservados para comparações com as previsões. Os da-

dos foram obtidos por meio do banco de dados da Associação Nacional dos Fabricantes de Veículos Automotores, disponíveis em <http://www.anfavea.com.br/estatisticas.html>. Tal base de dados não continha, no momento da pesquisa, informações sobre os meses posteriores a Abril de 2018.

Primeiramente, a série histórica foi decomposta em suas componentes de tendência, sazonalidade e parte aleatória e foi construído o gráfico de cada uma delas, a fim de se ter uma visão geral do comportamento da série. Esses gráficos podem revelar características importantes como a presença de tendência, sazonalidade, variabilidade, observações atípicas, etc. Realizou-se também uma análise descritiva, apresentando os valores mínimo, médio e máximo de automóveis exportados, além de algumas medidas que quantificam a dispersão dos dados, tais como o desvio-padrão e coeficiente de variação.

Foi investigada a estabilidade da variância através de um gráfico de amplitude versus média. Para a construção deste gráfico a série foi dividida em grupos de 12 observações e foram calculadas a média e a amplitude de cada grupo. Os valores das médias dos grupos foram registrados no eixo das abscissas e os valores das amplitudes dos grupos no eixo das ordenadas. Segundo Morettin e Toloi [1], se os pontos ficarem espalhados em torno de uma reta paralela ao eixo das abscissas, não haverá necessidade de transformação. Mas, se os valores das amplitudes forem diretamente proporcionais aos valores das médias é indicado utilizar uma transformação logarítmica nos dados da série. Na medida em que a interpretação gráfica possui um grau de subjetividade, procedeu-se a um teste de hipótese para o coeficiente angular da reta de regressão linear. O teste segue a estatística t e sua hipótese de nulidade é de que a inclinação da reta é nula, ou seja, as amplitudes independem das médias. Para um dado nível de significância α a hipótese de nulidade é rejeitada para p -valores menores que α , havendo então a necessidade de se utilizar uma transformação logarítmica.

A verificação da estacionariedade da série foi feita através do Teste de Dickey-Fuller Aumentado (DFA). Nesse teste, a hipótese nula (H_0) é de que a série apresenta raiz unitária e, portanto, não é estacionária. Nos casos em que a hipótese nula não é rejeitada, torna-se necessário o uso de procedimentos matemáticos, que consistem em tomar diferenças na série, a fim de torná-la estacionária. São tomadas tantas diferenças quantas forem necessárias para se obter uma série estacionária em nível. Porém, cabe ressaltar que um número de diferenças excessivo deve ser evitado. Quando isso ocorre, a variância da série aumenta e um valor negativo, próximo de -0,5, é obtido para a função de autocorrelação de ordem 1. Por outro lado, se a série é corretamente diferenciada a variância diminui. Para identificar o número de diferenças necessárias, ou seja, a ordem de integração do modelo, procedeu-se o teste de Dickey-Fuller Aumentado.

Após diferenciar corretamente a série, foi verificada a presença da componente Sazonalidade, que pode ser entendida como periodicidades presentes nos dados. Uma ferramenta utilizada para verificar a existência dessa componente em uma série temporal é o Periodograma. Trata-se de um gráfico no qual é possível perceber a presença de picos, que podem indicar sazonalidade se estiverem entre os primeiros doze períodos. Nesse caso, são realizados testes de hipótese nestes picos de período (p) para confirmar a presença de sazonalidade ou verificar se este pico é devido somente a uma flutuação aleatória. Um teste muito utilizado foi proposto por Fisher e consiste em testar o primeiro maior pico ($\max I_p$) entre os 12 primeiros períodos do Periodograma. A estatística do teste é dada por

$$g = \max I_p / \sum_{p=1}^{N/2} I_p,$$

sendo $\sum_{p=1}^{N/2} I_p$ o somatório das observações do Periodograma e N o número total de observações. Testa-se a hipótese de nulidade de que a série não possui sazonalidade de período p . Se comprovado que o valor da estatística g é superior ao valor de Z , dado por $Z = 1 - \left(\frac{\alpha}{n}\right)^{\frac{1}{n-1}}$ sendo $n = N/2$, conclui-se que a componente sazonal com periodicidade p é significativa.

ou seja, rejeita-se a hipótese de nulidade e a série apresenta sazonalidade de período p . A retirada das componentes de tendência e sazonalidade torna a série estacionária e permite a utilização dos modelos propostos por Box e Jenkins.

Para a série de produção de veículos, o modelo estatístico selecionado foi o SARIMA (Sazonal Autorregressivo Integrado e de Médias Móveis), que é adequado para modelagem de dados com autocorrelação periódica e inferior a um ano, o que caracteriza o efeito sazonal. A escolha dessa classe de modelos e a identificação dos mesmos foram feitas a partir das funções de autocorrelação e autocorrelação parcial da série estacionária. Tais modelos apresentam, além dos parâmetros autoregressivos de ordem p e de médias móveis de ordem q , parâmetros sazonais autoregressivos de ordem P e de médias móveis de ordem Q . Para identificação dos valores dos parâmetros q e p observa-se os lags iniciais das funções de autocorrelação e autocorrelação parcial respectivamente, e para os valores dos parâmetros Q e P observa-se respectivamente nas mesmas funções os lags múltiplos do período sazonal (s). A equação que descreve o modelo é:

$$\Theta(B)\Phi(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\phi(B^s)a_t \quad (1)$$

em que:

$\Theta(B) = 1 - \Theta_1(B^1) - \Theta_2(B^2) - \dots - \Theta_p(B^p)$ o polinômio autorregressivo de ordem p ;

$\Phi(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^s) - \dots - \Phi_P(B^P)$ o polinômio autorregressivo sazonal de ordem P ;

$\Delta^d = (1 - B^s)^d$ o operador diferença no qual d indica o número de diferenças de ordem 1 necessárias para retirar a tendência da série;

$\Delta_s^D = (1 - B^s)^D$ o operador diferença sazonal no qual D indica o número de diferenças de ordem s necessárias;

$\theta(B) = 1 - \theta_1(B^1) - \theta_2(B^2) - \dots - \theta_q(B^q)$ o polinômio de médias móveis de ordem q ;

$\phi(B^s) = 1 - \phi_1(B^s) - \phi_2(B^s) - \dots - \phi_Q(B^Q)$ o polinômio de médias móveis sazonal de ordem Q ;

Z_t a variável resposta do modelo;

a_t representa o erro aleatório e não observável do modelo ou ruído branco.

Em algumas séries pode ser notada a presença de observações atípicas que provocam uma mudança de nível na série ou da sua inclinação. Essa manifestação pode afetar temporariamente ou permanentemente a série de modo abrupto ou gradual e é denominada intervenção. Uma intervenção temporária é caracterizada por um impulso na série. Esse tipo de intervenção é incorporado ao modelo utilizando variáveis dummy do tipo:

$$X_{j,t} = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases} \quad (2)$$

Sendo assim, foram identificados diversos modelos da classe SARIMA, com e sem intervenção, e estimados seus parâmetros pelo método da máxima verossimilhança exata. Para cada um dos modelos ajustados, satisfazendo as condições de invertibilidade e unicidade dos parâmetros, foi verificado se os resíduos do modelo são ruído branco, utilizando-se para tal o teste de Ljung-Box (Morettin e Toloi [1]). A estatística do teste possui distribuição Qui-quadrado com $k-N$ graus de liberdade, dada na equação (3):

$$Q = N(N+2) \sum_{i=1}^k (N-i)^{-1} r_k^2, \quad (3)$$

em que k é o número de defasagens utilizadas e r_k é o valor estimado do k -ésimo coeficiente de autocorrelação serial. O p -valor é dado por $\text{Prob}[Q \geq X_{GL}^2]$. A hipótese de ruído branco para os resíduos foi rejeitada para p -valores inferiores ao nível de significância de 5%.

Além desse teste, o diagnóstico dos modelos também foi feito avaliando-se a função de autocorrelação. Nesse caso, considerou-se os modelos cujas funções de autocorrelação apresentavam no máximo 5% dos lags significativos, isto é, fora dos limites do intervalo de confiança.

Dentre os modelos que apresentaram resíduos caracterizados como ruído branco, foram selecionados os cinco modelos mais parcimoniosos por meio do Critério de Informação de Akaike (AIC). Esse critério considera o número de parâmetros do modelo ajustado e sua variância, sendo obtido através da equação (4):

$$AIC(l, k) = \ln \sigma_{k,l}^2 + 2(k + l)/N, \quad (4)$$

na qual $\sigma_{k,l}^2$ é uma estimativa da variância residual e N o número de observações da série.

Utilizando os modelos selecionados, foi realizada a previsão dos valores da quantidade de automóveis exportados no Brasil entre Novembro de 2017 e Abril de 2018. Para todos os modelos foi calculado o Erro Percentual Absoluto Médio (MAPE), cuja equação é dada em (5):

$$MAPE = \sum_{i=1}^k [(A_t - F_t)/A_t]/N, \quad (5)$$

sendo A_t a demanda real no período, F_t a previsão para o período t e N o número de períodos de previsão t.

O MAPE é a média de todos os erros absolutos percentuais e constitui um indicador da qualidade da previsão, na medida em que fornece uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente do erro ser positivo ou negativo (LOPES [16]). Para Lewis [17], o MAPE é considerado como uma das medidas de erro mais usadas para se avaliar os métodos de previsão. Assim, utilizou-se o MAPE como critério de escolha do modelo mais adequado, sendo este o que apresenta o menor MAPE.

Para a manipulação e análise estatística dos dados utilizou-se o software livre GRETL [18]. As análises foram feitas considerando um nível de significância α igual a 5%.

3 RESULTADOS E DISCUSSÕES

A Figura 1 apresenta o gráfico da série de exportação brasileira de automóveis no período de Janeiro de 2009 a Março de 2017 e sua decomposição nas componentes de tendência, sazonalidade e parte aleatória. A análise visual desses gráficos sugere que a série não é estacionária, pois oscila em torno de um nível que varia com o tempo, caracterizando uma possível tendência estocástica. Além disso, subentende-se a presença de sazonalidade aditiva através de um padrão periódico na série. Tais comportamentos necessitam de uma verificação objetiva, através de testes de hipóteses, que possam comprová-los.

A Tabela 1 apresenta uma análise descritiva da variável em estudo. Os altos valores obtidos para o desvio padrão e para o coeficiente de variação, aproximadamente 31%, indicam uma alta variabilidade dos valores observados em torno da média, o que corrobora para a suspeita inicial da existência de tendência na série.

No intuito de investigar a estabilidade da variância foi construído o gráfico de amplitude versus média, apresentado na Figura 2. A análise gráfica sugere que não há necessidade da utilização de transformação logarítmica. Para uma análise mais objetiva, foi feito o teste de hipóteses para o coeficiente de inclinação da reta de regressão linear, considerando-se um nível de significância de 5%. O p-valor obtido para o teste foi de 0,786161, indicando que não há a necessidade de transformação logarítmica.




FIGURA 1: Gráfico de decomposição da série temporal de exportação brasileira de automóveis

Medidas Estatísticas	Valores
Média	32695
Mínimo	12594
Máximo	59737
Desvio Padrão	10046
C. V.	30,73%

TABELA 1: Estatísticas descritivas da série de exportação brasileira de automóveis.

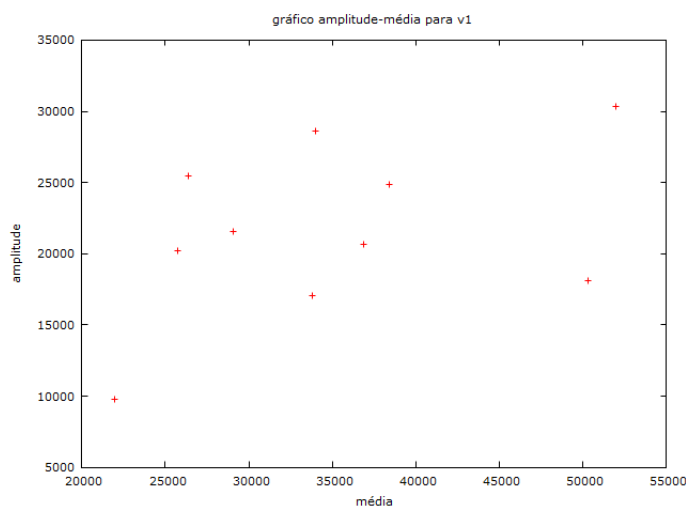


FIGURA 2: Gráfico Amplitude versus Média

Para verificar a presença de raiz unitária na série e a ordem de integração do modelo procedeu-se ao Teste de Dickey-Fuller Aumentado (DFA). De acordo com esse teste, a série possui raiz unitária, o que indica sua não estacionariedade, apresentando um p-valor de 0,9347. Ainda pelo teste, a presença de uma constante no modelo não é significativa, ao nível de 5%, e não melhora o ajuste do modelo, de acordo com o critério AIC, conforme Tabela 2. Para o modelo com tendência, o teste indicou que a ordem de integração do modelo é 1, pois a partir da segunda diferença não foi verificada significância. Ressalta-se que há um aumento da variância quando tomada a segunda diferença. Para a série

diferenciada uma vez o desvio padrão é de 8079,8 e para a segunda diferença o desvio padrão é de 13580. Assim, foi aplicado o operador diferença na série apenas uma vez, conforme os resultados obtidos no teste DFA.

Modelo	AIC
com constante	2045,99
sem constante	2044,96

TABELA 2: Valores do critério AIC do Teste DFA para os modelos com constante e sem constante.

A Figura 3 apresenta o gráfico da série diferenciada uma vez. Observando-a em conjunto com a Figura 1 notou-se a presença de observações atípicas nos meses de Maio de 2012 e Julho de 2015.




FIGURA 3: Gráfico da série diferenciada.

A partir da série diferenciada, foi construído o Periodograma, que se encontra na Figura 4, a fim de investigar a presença da componente Sazonal. Foi observado um pico de período 3 ($\text{Max } I_3 = 5,14\text{E}+07$) e então, foi aplicado o Teste de Fisher. O valor obtido para a estatística g foi de 0,100909533 e para Z foi de 0,125376703. Sendo assim, com 95% de confiança, não existem evidências para se rejeitar a hipótese de nulidade, ou seja, não existe periodicidade de período 3.




FIGURA 4: Periodograma da série estacionária.




FIGURA 5: Gráfico da autocorrelação e autocorrelação parcial da série estacionária.

A Figura 5 apresenta as funções de autocorrelação e autocorrelação parcial da série diferenciada. A observação das mesmas permitiu notar que decaem rapidamente para zero,

confirmando a estacionariedade da série. Além disso, foi possível notar a necessidade de identificar modelos com possíveis parâmetros sazonais. Foram tomados os valores 0, 1 ou 2 para o parâmetro p e 0 ou 1 para os parâmetros q , P e Q e testados modelos com todas as combinações possíveis para esses valores dos parâmetros. Foram ajustados modelos com e sem intervenção, considerando intervenções ocorridas em Maio de 2012 e Julho de 2015. Os seis modelos mais parcimoniosos, de acordo com o critério AIC foram selecionados. Os p -valores do Teste Box Pierce e os valores dos critérios AIC para cada um deles encontra-se na Tabela 3.

MODELO	MAPE	Ljung-Box(p-valor)	AIC
$(0, 1, 1)(0, 0, 0)_{12}$	15,786	0,188	2158,77
$(0, 1, 1)(0, 0, 1)_{12}$	13,241	0,391	2154,175
$(1, 1, 0)(0, 0, 1)_{12}$ c/ interv. Jul/2015	13,86	0,532	2156,769
$(1, 1, 0)(1, 0, 0)_{12}$ c/ interv. Mai/2012 e Jul/2015	12,458	0,79	2150,193
$(0, 1, 1)(1, 0, 0)_{12}$	12,486	0,469	2155,367
$(0, 1, 1)(1, 0, 0)_{12}$ c/ interv. Mai/2012	12,37	0,811	2149,115

TABELA 3: Modelos selecionados pelo critério AIC, seus valores de MAPE e p -valores do teste Ljung-Box.

Utilizando-se dos p -valores indicados na Tabela 3 para o teste de Ljung-Box, pode-se dizer que não existem evidências para se rejeitar a hipótese de ruído branco para os resíduos, ao nível de significância de 5%. Portanto, os modelos selecionados segundo o AIC apresentam resíduos independentes e normalmente distribuídos.

Para cada um desses modelos o valor obtido para o Erro Absoluto Percentual Médio (MAPE) também encontra-se na Tabela 3. Pode ser observado que o modelo que forneceu o menor MAPE foi o SARIMA $(0, 1, 1)(1, 0, 0)_{12}$ com intervenção em Maio de 2012, sendo este o escolhido como o mais adequado para a modelagem da série. Segundo Wyatt [19], considera-se que as previsões são boas, pois o MAPE foi inferior a 15%.

A intervenção observada, que provocou queda nas exportações em 2012, justifica-se pela falta de competitividade dos produtos brasileiros ocorrida no período e à crise econômica que afetava os mercados europeus (Pogetto [20]).

A Tabela 4 apresenta as estimativas para os parâmetros e seus respectivos erros padrão e p -valores.

Parâmetro	Estimativa	Erro padrão	p -valor
θ_1	-0,480848	0,0855898	$1,93e - 08$
Φ_1	0,325689	0,106144	0,0022
ω_1	-18704,5	5407,95	0,0005

TABELA 4: Parâmetros do modelo de suas estimativas.

Assim, a série pode ser estatisticamente representada pela seguinte expressão:

$$Z_t = -18704,5X_{1,t} + \frac{(1 + 0,480848B)a_t}{(1 - 0,325689B^{12})(1 - B)}, \tag{6}$$

em que a variável dummy é:

$$X_{1,t} = \begin{cases} 0, & t \neq 41 \\ 1, & t = 41 \end{cases}$$

Na Tabela 5 são apresentadas informações sobre a previsão para Novembro de 2017 a Abril de 2018, utilizando-se o modelo SARIMA $(0, 1, 1)(1, 0, 0)_{12}$ com intervenção em Maio de 2012. Nessa tabela podem ser vistos os valores reais, os valores previstos, o erro de previsão (resíduo) e os limites dos intervalos de 95% de confiança a cada mês.

Mês/Ano	Valor real	Previsto	Resíduo	Limite Inferior	Limite Superior
2017:11	61586,00	55424,87	6161,13	42816,53	68033,21
2017:12	52247,00	55399,47	-3052,47	41193,28	69605,66
2018:01	38006,00	50029,50	-12023,5	34387,85	65671,15
2018:02	54932,00	57261,11	2329,11	40305,08	74217,13
2018:03	52242,00	58706,52	-6464,52	40530,92	76882,11
2018:04	56084,00	56313,68	-229,68	36995,35	75632,00

TABELA 5: Estimativas para os meses de Novembro de 2017 a Abril 2018 utilizando-se o modelo SARIMA(0, 1, 1)(1, 0, 0)₁₂ com intervenção em Maio de 2012.




FIGURA 6: Gráfico do modelo ajustado juntamente à série original.

A Figura 6 apresenta o gráfico do modelo ajustado sobreposto ao gráfico da série original. Pode ser observado que o modelo ajustado conseguiu captar a dinâmica temporal da série.

A fim de complementar os resultados, foram feitas previsões para doze meses, de Maio de 2018 a Abril de 2019, utilizando o modelo ajustado. A Figura 7 apresenta o gráfico dos valores preditos e seus respectivos intervalos de 95% de confiança. Ressalta-se que previsões mais precisas podem ser obtidas se houver uma atualização periódica dos dados, incorporando os novos valores ao conjunto de dados e refazendo a análise.

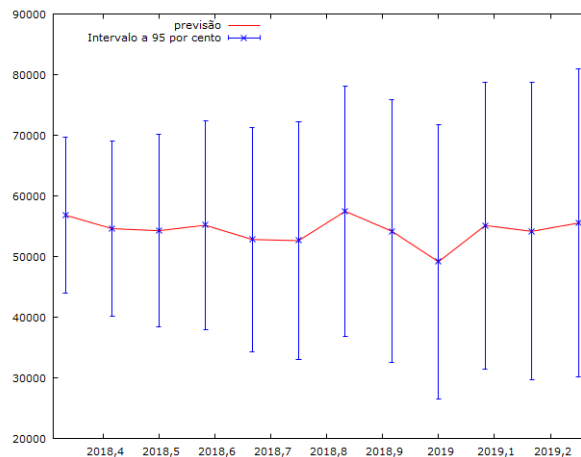


FIGURA 7: Previsão e Intervalos de Confiança a 95%

4 CONCLUSÃO

A série de exportação brasileira de automóveis apresentou, no período de Janeiro de 2009 a Abril de 2018, um comportamento não estacionário necessitando de modelos integrados que incluam parâmetros sazonais em seu ajuste. Nesse sentido, empregou-se a metodologia Box & Jenkins, e foram propostos modelos da classe SARIMA, com e sem intervenção, para desenvolver previsões e obter estimativas para a série de exportação brasileira de automóveis.

Foram selecionados os seis modelos que apresentaram o menor valor de AIC e cujos resíduos possuem características de ruído branco, o que corroborou para a qualidade do ajuste. Dentre estes, assim como Tidre [4], o modelo mais adequado para a modelagem foi um modelo com intervenção. O SARIMA(0, 1, 1)(1, 0, 0)₁₂ com intervenção em Maio de 2012 apresentou o menor valor do MAPE, sendo este o escolhido. A intervenção se justifica na falta de competitividade dos produtos brasileiros e na crise econômica que afetava os mercados europeus em 2012. Dessa forma, a metodologia de Box e Jenkins utilizada mostrou-se adequada para a modelagem da exportação brasileira de automóveis e para a previsão de valores futuros, visto que o MAPE foi inferior a 15%.

As previsões fornecidas pelo modelo ajustado para os meses de Novembro de 2017 a Abril de 2018 foram próximas dos valores reais. Observa-se também que estes valores reais situam-se dentro dos intervalos de confiança de 95% para a previsão. Isto significa que o modelo conseguiu captar a dinâmica temporal da série.

Ressalta-se que a exportação é a atividade que proporciona a abertura do país para o mundo. É uma forma de se confrontar com os demais parceiros, conhecer concorrentes e técnicas que não teriam acesso em seu mercado interno, além de poder equilibrar contas externas e promoção do desenvolvimento econômico. Desta forma, espera-se que os resultados apresentados na Figura 7, possam vir a contribuir de forma despreziosa para estudos de planejamento e controle do mercado de exportações, importante setor da economia brasileira.

REFERÊNCIAS

- [1] P. Morettin and C. M. C. Toloi, *Análise de séries temporais*. 2.ed. São Paulo: Edgard Blücher/ABE-Projeto Fisher, 2006.
- [2] C. D. Lewis, *Demand Forecasting and Inventory Control*. New York: Wiley, 1997.
- [3] E. Barbosa, T. Sáfyadi, M. Nascimento, A. Nascimento, C. O. Silva, and R. Manuli, "Metodologia Box & Jenkins para previsão de temperatura média mensal da cidade de Bauru (SP)," *Rev. Bras. Biom.*, vol. 33, pp. 104–117, 2015.
- [4] P. Tidre, N. G. Biasse, and M. I. S. Silva, "Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil.," *Revista Eletrônica Matemática e Estatística em Foco*, vol. 01, pp. 57–66, 2013.
- [5] L. T. P. Giarola, F. O. Takenaka, and R. C. Rocha, "Modelo aplicado à previsão da demanda de energia elétrica do campus do Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG).," *Revista da Estatística da Universidade Federal de Ouro Preto*, vol. III-03, pp. 599–603, 2014.
- [6] M. A. Santili, "Métodos de previsão auto-regressivos aplicado a uma série de volume de produção de caminhões." 2015. 48 f. Trabalho de conclusão de curso (Bacharelado - Engenharia Mecânica) - Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2015. Disponível em: <http://hdl.handle.net/11449/139106>. Acesso em: 31/05/2018.

- [7] F. M. Souza, “Modelos Box & Jenkins aplicados a previsão de demanda de leitos hospitalares..” Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS), 2006. Disponível em <http://w3.ufsm.br/adriano/mon/fm.pdf> Acesso em: 31/05/2018.
- [8] S. M. Micaelo, “Evolução da estratégia da Fiat Automóveis S.A. face à mudança do ambiente competitivo da indústria automobilística brasileira: Um estudo de caso..” Master’s thesis, Pontifícia Universidade Católica do Rio de Janeiro, 2003.
- [9] D. C. Barros and L. S. Pedro, “As mudanças estruturais do setor automotivo: os impactos da crise e as perspectivas para o Brasil..” *BNDES Setorial*, vol. 34, pp. 173–202, 2011.
- [10] P. Brasil, “Setembro registra segundo maior superávit de 2013..” 2013. Disponível em <http://www.brasil.gov.br/economia-e-emprego/2013/10/setembro-registra-segundo-maior-superavit-de-2013> Acesso em: 31/05/2018.
- [11] A. Martello, “Exportações de automóveis sobem 46% e batem recorde em 2013..” 2014. Disponível em <http://g1.globo.com/carros/noticia/2014/01/exportacoes-de-automoveis-sobem-46-e-batem-recorde-em-2013.html> Acesso em: 31/05/2018.
- [12] P. Fussy, “Produção de veículos sobe 17,1% em janeiro de 2017, diz Anfavea..” 2017. Disponível em <https://g1.globo.com/carros/noticia/producao-de-veiculos-sobe-171-em-janeiro-de-2017-diz-anfavea.ghtml> Acesso em: 31/05/2018.
- [13] A. A. Salles, P. E. Arantes, and C. C. Tavares, “Um estudo da série de vendas de automóveis no Brasil através de métodos clássicos de previsão de demanda,” 2010. Disponível em <http://www.anpad.org.br/admin/pdf/gol2090.pdf> Acesso em: 31/05/2018.
- [14] J. P. Guarnieri, A. M. Souza, S. G. de Almeida, F. M. Souza, and J. N. D. de Oliveira, “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.
- [15] M. das Relações Exteriores Brasil, *Exportação Passo a Passo*, 2005. Disponível em <http://www.investexportbrasil.gov.br/sites/default/files/publicacoes/manuais/PUBExportPassoPasso2012.pdf> Acesso em: 31/05/2018.
- [16] R. D. Lopes, “Previsão de autopeças: Estudo de caso em uma concessionária de veículos,” Master’s thesis, Universidade Federal de Santa Catarina, Centro Tecnológico., 2002. Disponível em <https://repositorio.ufsc.br/handle/123456789/83593> Acesso em: 31/05/2018.
- [17] G. Box and G. Jenkins, *Time series analysis, forecasting and control*. San Francisco: Holden-Day, 1976.
- [18] A. Cottrell, “Gretl - Gnu Regression, Econometrics and Time-series library. Wake Forest University..” 2003.
- [19] N. Wyatt, *The financial times essential guide to budgeting and forecasting: how to deliver accurate numbers*. Londres: Pearson UK, 2012.
- [20] P. D. Poggetto, “Produção de veículos cai 1,9% em 2012, apesar do recorde de vendas,” 2013. Disponível em <http://g1.globo.com/carros/noticia/2013/01/producao-de-veiculos-cai-19-em-2012-apesar-do-recorde-de-vendas.html> Acesso em: 31/05/2018.