

O Efeito das Crises Econômicas Mundiais na Volatilidade da Produção de Automóveis no Brasil

The Global Economic crises Effects in The volatility of National Production of Automobiles

Letícia Marasca

Graduação em Administração pela Universidade Regional Integrada do Alto Uruguai e das Missões
E-mail: leticiamarasca@yahoo.com.br

Adriano Mendonça Souza

Doutor em Engenharia de Produção pela Universidade Federal de Santa Catarina
Professor da Universidade Federal de Santa Maria
E-mail: amsouza.sm@gmail.com

Endereço: Letícia Marasca

Endereço: Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Departamento de Estatística. Laboratório de Análise e Modelagem Estatística – LAME – sala 1205-C. Campus Universitário – Camobi. Cep.: 97119-900 - Santa Maria, RS – Brasil.

Endereço: Adriano Mendonça Souza

Endereço: Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Departamento de Estatística. Sala 1205-C. Campus Universitário – Camobi. Cep.: 97119-900 - Santa Maria, RS – Brasil

Editor Científico: Tonny Kerley de Alencar Rodrigues

Artigo recebido em 24/08/2016. Última versão recebida em 16/09/2016. Aprovado em 17/09/2016.

Avaliado pelo sistema Triple Review: a) Desk Review pelo Editor-Chefe; e b) Double Blind Review (avaliação cega por dois avaliadores da área).

Revisão: Gramatical, Normativa e de Formatação.

Apoio e financiamento: Agradecemos ao LAME – Laboratório de Análise e Modelagem Estatística da Universidade Federal de Santa Maria – UFSM, pelo espaço utilizado, assim como softwares e equipamentos.

RESUMO

O Brasil tem papel de destaque no consumo e na produção de automóveis, sendo esta produção sujeita ao desempenho econômico do país. Este estudo tem como objetivo estimar um modelo linear de classe geral ARIMA, para prever o comportamento da Série de Produção Nacional de Automóveis e um modelo não linear da classe geral ARCH, para compreender os efeitos de volatilidade da série, auxiliando os fabricantes de automóveis no país no planejamento de sua produção. Os dados foram coletados mensalmente e retirados do site da Associação Nacional dos Fabricantes de Veículos Automotores – ANFAVEA, e correspondem à fabricação nacional de automóveis, no período de janeiro de 1957 até fevereiro de 2016, formando uma Série Histórica Nacional da Produção de Automóveis, com 710 observações. A metodologia empregada é da modelagem ARIMA e os modelos heterocedásticos ARCH. Com base no modelo ajustado, foi possível a realização de previsão *in sample*. O processo gerador da série é um autoregressivo de ordem 1, com uma diferença necessária para tornar a série estacionária, com efeito sazonal no lag 12, apresentando ainda heterocedasticidade de ordem 1.

Palavras-chave: Produção Nacional de Automóveis. Desempenho Econômico. Modelo ARIMA. Modelo ARCH.

ABSTRACT

Brazil is featured on consumption and automobiles production, being this production subject to economic country's performance. This study aims to fit an ARIMA linear model to forecast the Series National Production of Automobiles behavior and a non-linear model of general ARCH class to understand the volatility's effects of the series, helping Brazilian automobiles manufacturers on planning their production. Data collection was monthly and they were taken from Associação Nacional dos Fabricantes de Veículos Automotores – ANFAVEA's website, correspond to the national production of automobiles in the period from January 1957 to February 2016, and compose a Historical Series National Production of Automobiles, with 710 observations. The methodology is the ARIMA modeling and heteroskedastic models ARCH. Based on the adjusted model, it was possible the forecast's realization *in sample*. Series's generator process is an autoregressive of order 1, with a difference needed to become the stationary series, seasonal effect on the lag 12, and heterocedasticity of order 1.

Keywords: National Production of Automobiles. Economic Performance. ARIMA Model. ARCH Model.

1 INTRODUÇÃO

O Brasil tem papel de destaque no consumo e na produção de automóveis, pois a produção nacional de veículos o classifica como o 7º maior produtor do mundo em 2015, segundo o MDIC – Ministério do Desenvolvimento, Indústria e Comércio Exterior (MDIC, 2016).

O setor automotivo tem importante papel no setor industrial e no Brasil, este segmento representa 23% do PIB manufatureiro, sendo um setor que afeta significativamente a produção de diversos outros setores no país e no mundo.

A economia deste setor tem desacelerado nos últimos anos, e o que a manteve aquecida foi a isenção de IPI, estímulo fiscal fundamental para fortalecer segmento. Em 2009, período em que a isenção vigorou, as vendas tiveram um crescimento histórico. Comparativamente, neste ano, no mês de fevereiro de 2016, percebeu-se uma queda de quase 40%, quando comparado ao mesmo período do ano anterior, o que se pode considerar o pior resultado desde 2002, segundo a ANFAVEA – Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA, 2016). Com a queda na produção e vendas de automóveis, percebe-se uma perda de competitividade da indústria automobilística brasileira em relação a outros países. Um dos principais motivos para isto é a adoção, pelo governo, da política de câmbio flutuante e, ainda, a alta carga tributária, somada à carência de linhas de financiamento de exportação com taxas adequadas, pois as regras de exportações existentes no Brasil oneram ainda mais a produção, ao invés de estimulá-la.

Sabe-se que a produção de automóveis está sujeita ao desempenho econômico do país, pois muitos insumos sofrem diretamente a variação de preços na sua origem, tais como metais, energia, mão de obra especializada, entre outros fatores de menor impacto, mas não menos importantes.

A oscilação na economia pode refletir uma oscilação na produção, dado a isto tem-se como objetivo estimar um modelo linear de classe geral ARIMA, para prever o comportamento médio da série de produção e um modelo não linear da classe geral ARCH, para se compreender os efeitos de volatilidade da série de produção nacional de automóveis, auxiliando, com isso, os fabricantes de automóveis no país no planejamento de sua produção.

Esta pesquisa apresenta-se estruturada em cinco sessões. Esta primeira sessão oferece uma sucinta introdução. A segunda e terceira sessão nos fornece o referencial teórico acerca das metodologias utilizadas. A quarta sessão apresenta os dados e os procedimentos

metodológicos aplicados. Na quinta sessão estão as aplicações e discussões e por fim, na sexta sessão, estão as conclusões.

2 REFERENCIAL TEÓRICO

2.1 Metodologia Box e Jenkins

Baseados em pesquisas existentes, Box e Jenkins (1970) apresentaram uma metodologia para modelos de previsão de séries temporais. Em 1926, Yule havia apresentado os modelos autoregressivos (AR) e, em 1937 surgiram os modelos médias móveis (MA) com Slutsky. Wold, em 1938, provou que os modelos estacionários podem ser representados por modelos autoregressivos e médias móveis. A partir disso, Box e Jenkins traz a metodologia que contém as técnicas de identificação do modelo, a posterior estimação dos parâmetros e a verificação do modelo escolhido, hoje conhecida como metodologia Box e Jenkins (KIRCHNER *et al.*, 2011).

A metodologia Box e Jenkins é também conhecida como Modelos Autoregressivos Integrados de Média Móvel (*Autoregressive Integrated Moving Average*) ou ainda ARIMA (p,d,q), onde p é o número de parâmetros autoregressivos, d é o número de diferenças necessárias para tornar a série estacionária e q é o número de parâmetros médias móveis a serem estimados. A metodologia consiste na combinação de componentes, também conhecidos na literatura como filtros: componente autoregressivo (AR), filtro de integração (I) e componente de médias móveis (MA), podendo ser utilizados os 3 filtros, ou apenas a combinação de alguns deles (GUARNIERI *et al.*, 2009). A aplicação destes filtros se dá em séries temporais, que são observações cronológicas, equidistantes ao longo do tempo, auto correlacionadas entre si e que tem por objetivo estudar o processo gerador da série, que busca compreender o comportamento da variável, por meio de um modelo que melhor represente as características da série original. Verifica-se, assim, se ela pode ser representada por um modelo autoregressivo AR (p), descrito pelos seus valores passados e pelo ruído branco, por um modelo de médias móveis MA (q), ou ainda por um modelo autoregressivo, de médias móveis ARMA (p, q), descrito pelos seus valores passados e pelos choques aleatórios, ou por um processo misto autoregressivo integrado de médias móveis ARIMA (p,d,q), que é ajustado em séries que eram não-estacionárias, e se tornaram estacionárias após a aplicação das diferenças (WALTER *et al.*, 2010).

Os modelos citados podem ser representados pelas equações 1 a 4.

$$\text{AR} \quad Z_t = \mu + \phi Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (1)$$

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

$$\text{ARMA} \quad Z_t = \mu + \phi Z_{t-1} + \dots + \phi_p Z_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (3)$$

$$\text{ARIMA} \quad \Delta^d Z_t = \mu + \phi_1 \Delta^d Z_{t-1} + \dots + \phi_p \Delta^d Z_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (4)$$

Onde: $\theta_1 \rightarrow \theta_q \rightarrow$ parâmetro AR;

$\phi_1 \rightarrow \phi_q \rightarrow$ parâmetro MA;

$\mu \rightarrow$ média do processo;

$\Delta^d \rightarrow$ número de diferenças para tornar a série estacionária;

$Z_t \rightarrow$ a série original;

$\varepsilon_t \rightarrow$ resíduos.

Para aplicação dos modelos de Box e Jenkins, as séries devem ser estacionárias, garantindo que os parâmetros estimados sejam representativos para toda a série. A não estacionariedade em uma série temporal é identificada pela presença de movimentos ascendentes ou descendentes na série. No caso da série ser estacionária, há uma oscilação em torno de uma média e variância constantes, não se alterando com o tempo, durante o período de análise (MORETTIN; TOLOI, 2006).

Esta importante condição de estacionariedade pode ser verificada através dos testes: teste de raiz unitária de Dickley-Fuller Aumentado – ADF (1979), e o teste Kwiatkowski, Phillips, Schmidt e Shin - KPSS (1992). A literatura nos traz a importância da utilização conjunta destes testes, uma vez que um corrobora o resultado do outro (Patterson, 2000).

As séries não-estacionárias deverão sofrer transformações para se tornarem estacionárias, sendo que a primeira diferença (d=1) aplicada na série geralmente estabiliza a média (estacionariedade de primeira ordem), e a segunda, (d=2), estabiliza a variância (estacionariedade de segunda ordem) (SOUZA *et al.*, 2013). Deve se ter muito cuidado ao se realizar diferenças, pois o excesso de diferenças pode incluir erros no modelo, prejudicando o seu desempenho final.

Para identificação do modelo a ser estimado, observam-se os gráficos correspondentes à Função de Auto Correlação (FAC) e à Função de Auto Correlação Parcial (FACP). O comportamento dessas funções, além de indicar qual o filtro deverá ser utilizado, auxilia no uso dos testes de raízes unitárias, para confirmação da estacionariedade da série (WERNER; RIBEIRO, 2003). Gerados os gráficos da FAC e FACP, pode-se observar o comportamento das funções: quando a FAC da série de dados decai exponencialmente, chegando a zero nas primeiras defasagens, tem-se a indicação de um modelo AR. Ao observar a FACP da série, pode-se perceber a ordem do processo, ou a quantidade de parâmetros p do modelo estimado. No caso do modelo estimado ser um MA, percebe-se na FAC os lags significativos para definir a quantidade de parâmetros q do modelo, e na função FACP, ela deverá decair exponencialmente (MORETTIN; TOLOI, 2006).

O erro do modelo, que consiste na diferença entre o valor previsto e o valor real da série, também denominado de resíduo, é uma medida essencial para verificar a validação do modelo. A escolha do melhor modelo se dará pelo erro apresentado: quanto menor o erro, melhor será o modelo. O que se busca, neste momento, é encontrar resíduos com características de ruído branco: o erro com média zero, variância constante e que seja não auto correlacionados ($\epsilon_t \sim N(0, \sigma_\epsilon^2)$) (SOUZA *et al.*, 2015).

Depois de se chegar a diversos modelos concorrentes, a escolha do melhor se dá pelos critérios penalizadores *Bayesian Information Criterion* – *BIC* (equação 5) e *Akaike Information Criterion* – *AIC* (equação 6), que tem a minimização dos critérios penalizadores como fator decisivo para a definição da escolha, ou seja, o modelo que mais se ajustará à série original será o mais parcimonioso: o que apresentar os menores valores de *AIC* e *BIC*. Ainda outro critério utilizado é o da parcimônia, que contempla os modelos com menor número de parâmetros.

$$BIC = \ln \hat{\sigma}^2 + n \frac{\ln T}{T} \quad (5)$$

$$AIC = \ln \hat{\sigma}^2 + n \frac{2}{T}, \quad (6)$$

Onde: $\hat{\sigma}^2 \rightarrow$ é a variância do erro;

$T \rightarrow$ é o número de observações utilizadas;

$n \rightarrow$ é o número de parâmetros estimados.

Após a escolha do modelo que melhor se ajusta à base de dados, devem-se testar as estatísticas de previsão com os testes U-Theil (7), MAPE (8) e EQM (9). Essas estatísticas atuam como parâmetros de avaliação quanto à capacidade preditiva dos modelos perante os dados originais, testando o quanto o método de previsão é melhor, quando comparado à previsão ingênua (KLIDZIO, 2009).

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{y_{t+1} - \bar{y}_t}{y_t} \right)^2}{\sum_{t=1}^{n-1} \left(\frac{y_{t+1} - y_t}{y_t} \right)^2}} \quad (7)$$

$$MAPE (\%) = \frac{\sum \left(\frac{e_t}{y_t} \right)}{n} \cdot 100 \quad (8)$$

$$EQM = \frac{\sum_{t=1}^n e_t^2}{n} \quad (9)$$

Onde: $n \rightarrow$ é o número de observações;

$y_t \rightarrow$ é o valor observado no instante t ;

$y_{t+1} \rightarrow$ é o valor observado no instante $t+1$;

$\bar{y}_t \rightarrow$ é o valor previsto para o instante t ;

$e_t^2 \rightarrow$ é o erro de previsão ao quadrado no instante t .

2.2 Modelagem Arch

Ao ajustar os modelos econométricos, espera-se que a variância dos resíduos gerados seja constante, com isso, o princípio da homocedasticidade é aceito. Quando isso não ocorre e a variância dos resíduos não é constante, ocorre o efeito denominado heterocedasticidade. A presença de heterocedasticidade no momento da estimação do modelo gera parâmetros não eficientes, com erros que podem afetar as previsões (VAL, 2006).

Essas séries apresentam variabilidade (volatilidade) variável ao longo do tempo, onde o valor esperado dos erros quadráticos $E(\varepsilon_t \cdot \varepsilon_t)$ não são constantes. Os modelos apropriados para modelagem neste caso são os modelos heterocedásticos, que vão além do modelo ARIMA, pois modelam o resíduo quadrático que foi encontrado e que possui características de ruído branco (ARÊDES, 2008). Na classe dos modelos heterocedásticos, o primeiro

modelo desenvolvido para estimação da volatilidade foi proposto por Engle (1982), e denominado de ARCH (Autoregressive Conditional Heterocedasticity, ou Modelo Autoregressivo de Heterocedasticidade Condicional), um dos mais utilizados atualmente.

A ideia principal do modelo ARCH é o fato de que a variância de ϵ_t , no período de tempo t , depende de ϵ_{t-1}^2 . Como a variabilidade pode ser explicada pela volatilidade existente entre os erros oriundos do modelo de previsão linear, pode-se observar que a variância destes erros não é constante ao longo do tempo, mas varia de um período para outro, existindo uma autocorrelação na variância dos erros de previsão (BOLLERSLEV, 1986; GUJARATI, 2000; VASCONCELLOS, 2007).

O termo de erro ϵ_t , condicionado à informação disponível no período $(t-1)$ seria distribuído conforme a seguinte notação:

$$\epsilon_t \sim N[0, (\alpha_0 + \alpha_1 \epsilon_{t-1}^2)] \quad (10)$$

Onde α_0 e α_1 são parâmetros explicativos da variância do termo de erro ϵ_t (CAMPOS, 2007).

Um modelo ARCH(m), em que m denota a ordem do modelo, expressa a variância condicional do modelo para a média condicional, como uma função das inovações quadráticas passadas (SILVA; SÁFADI; CASTRO JUNIOR, 2005).

Segundo Moretin (2008), o modelo ARCH(m) é definido por:

$$r_t = \sqrt{h_t} \epsilon_t \quad (11)$$

$$h_t = \alpha_0 + \alpha_1 r_{t-1}^2 + \dots + \alpha_m r_{t-m}^2 \quad (12)$$

em que ϵ_t é *i.i.d.* com média zero, e h_t é a variância condicional.

Para assegurar que a variância condicional seja positiva e fracamente estacionária, as seguintes restrições paramétricas são necessárias: $\alpha_0 > 0$, $\alpha_1 \geq 0$, para todo $t=2, \dots, m$ e $\sum \alpha_1 < 1$. E, sob a condição de estacionariedade, a variância será dada por:

$$Var(r_t) = \frac{\alpha_0}{1 - \sum_{t=2}^m \alpha_t} \quad (13)$$

Na prática, seguindo o modelo original de Engle, assume-se que ϵ_t tem distribuição normal ou *t-Student* padronizada. Pela própria definição, valores grandes de r_t^2 são seguidos por outros valores grandes da série. Se admitirmos que r_t^2 siga um modelo ARCH, as caudas serão mais pesadas do que as da normal, o que é uma propriedade característica do modelo; portanto, o excesso de curtose é uma medida que auxilia na identificação da presença de volatilidade (BAYER, 2008). Campos (2007) diz que, se a assimetria é diferente de zero e a curtose é maior que três, isso significa que a série pode exibir sinais de volatilidade e de *clusters* de volatilidade, isto é, os dados são agrupados no centro da distribuição juntamente com algumas observações nos extremos das caudas. Outras fontes de consulta são Morettin (2006), Bueno (2008), Enders (1995) e Hamilton (1994).

3 METODOLOGIA

O banco de dados utilizado para a modelagem foi obtido no site da Associação Nacional dos Fabricantes de Veículos Automotores –ANFAVEA, e corresponde à fabricação mensal nacional de automóveis. O período de estudo começa em janeiro de 1957 e vai até fevereiro de 2016, com registros mensais da produção de automóveis, compreendendo 710 observações.

As etapas cumpridas para se chegar ao modelo que melhor se ajusta à série são:

Analisar a estabilidade da série, para verificar a necessidade, ou não, de diferenciá-la, por meio dos testes ADF e KPSS;

Traçar a FAC e a FACP da série, de modo a identificar os filtros a serem utilizados (AR, MA, ARMA, ou ARIMA), e suas defasagens;

Após identificar o filtro, realiza-se a estimação por meio do Método da Máxima Verossimilhança.

Finalmente, ocorre a investigação dos resíduos pelos critérios penalizadores *AIC* e *BIC*, definindo, assim, o melhor modelo entre os modelos concorrentes. As previsões serão realizadas com o melhor modelo ajustado.

Encontrado o melhor modelo, utilizam-se os resíduos quadráticos para modelar por meio do modelo ARCH, nesta etapa, as etapas similares ao procedimento da metodologia Box e Jenkins são utilizadas, inclusive a análise dos resíduos.

O software utilizado para modelagem dos dados foi o EViews 9 S.V.

4 RESULTADOS E DISCUSSÃO

Os dados coletados para modelagem formam uma série histórica nacional da produção de automóveis, totalizando 710 observações, coletadas mensalmente.

Com a inspeção gráfica da série original em estudo, na Figura 1, pode-se perceber que esta possui uma tendência crescente. Ao observar seus picos e vales, estes levam a supor que ela apresenta uma suave sazonalidade, o que não pode ser confirmado apenas visualmente, devido ao grande número de observações da série, mas que será confirmada através da FAC e FACP. Ao observar a série original, pode-se perceber que ela é não-estacionária. A partir disso, torna-se necessário aplicar uma diferença, para torná-la estacionária, conforme Figura 2, tornando possível assim a estabilidade dos parâmetros estimados.

Figura 1 – Possui uma tendência crescente.




Figura 1 - Série Histórica da Produção Nacional de Automóveis

Ainda na Figura 1 é possível observar graficamente o comportamento temporal da produção mensal de automóveis no Brasil, esta série apresenta um comportamento assimétrico e sinais da presença de volatilidade. Estes fortes sinais de assimetria indicam que esses choques (positivos e negativos) têm impactos sobre a série, fato que será comprovado posteriormente com a utilização da modelagem ARCH. Percebe-se que esses choques repercutem por algum período na série, até esta se estabilizar novamente.

A indústria automobilística teve diversos períodos importantes, compostos por quedas ou elevações representativas na produção de automóveis. Alguns acontecimentos endógenos e exógenos influenciaram significativamente na produção, e serão citados e terão suas causas analisadas a seguir.

Pela análise da Figura 1, percebe-se que a série manteve um crescimento gradual, permanecendo estável, desde o início das observações até o ano de 1980, quando se pode perceber o início da volatilidade variável da série. Neste ano (1980), percebe-se, logo no início uma queda brusca na produção e logo após um novo crescimento, para, em 1981, sentir o efeito de outra grande queda. Este período coincide com o início da crise dos Anos 80 no país, juntamente com uma troca de governos, do governo Geisel para o governo Figueiredo. Uma situação fiscal crítica no Estado e ainda o cenário internacional evidenciou a vulnerabilidade da economia brasileira com a elevação das taxas de juros internacionais e, como reflexo, teve-se, aqui, uma inflação com tendência ascendente.

Após isso, a série de produção nacional de automóveis se mantém estável, até 1985, ano em que se percebe outro grande vale, reflexo de 1984, ano em que ocorreu a reforma monetária no país, que eliminou a unidade de centavos, através da Lei nº 7.214 (SAMOBYL *et al.*, 2002). Depois dessa queda de 1985, nota-se uma estabilização na série, até o período de 1990. Nos períodos posteriores, a série segue instável com diversos picos e quedas também em 1991 e 1992, instabilidade esta associada à eleição do Presidente da República Fernando Collor de Mello, em 1990, (ano em que ocorreu a implementação do Plano de Estabilização Econômica, denominado de *Plano Collor I*). No ano seguinte (1991), ainda associado a esta instabilidade, ocorreu a implementação do Plano de Estabilidade Econômica, denominado de *Plano Collor II*. Outro motivo desta instabilidade observada na série neste período foi o *impeachment* do então Presidente da República, Fernando Collor de Mello, ocorrido em 1992. Neste ano também a série se mantém estável, assim como a produção de automóveis, e pode-se associar esta estabilidade às mudanças favoráveis à economia da época, como a instituição da moeda chamada Cruzeiro Real (CR\$), através da Resolução nº 2010, que ocorreu no ano de 1993. Pode-se perceber que, no período que se seguiu (1992 a 1997), a estabilidade se manteve até o ano de 1998, tendo-se constatado quedas por 2 anos seguidos (1998 e 1999), fato este que se associa à Crise Asiática, juntamente com a desvalorização das Moedas Asiáticas, ocorrido um ano antes (1997), e a Crise da Rússia, com a Decretação da Moratória Russa, ocorrido no ano seguinte (1998). No ano de 1999, pode-se visualizar um vale, que associamos aos efeitos das crises financeiras internacionais sobre a economia do país, que levaram o Real (R\$) a ser desvalorizado.

No próximo período, percebe-se, graficamente, (Figura 1), um grande crescimento na produção de automóveis no Brasil, período este que vai do ano de 2000, até o ano de 2008. Em 2009 ocorre outra grande queda, como um reflexo da crise econômica internacional ocorrida em 2008, que só começa a ser sentida nacionalmente em 2009. Durante os anos de 2010 a 2013, pela inspeção gráfica, (Figura 1), percebe-se que a produção se mantém estável, apresentando um leve crescimento. O crescimento constante apresentado no período foi uma tentativa do Governo Federal de incentivar a produção de automóveis, facilitando a compra de automóveis pela redução do Imposto sobre Produtos Industrializados (IPI) mas, desde 2014, ano de transição do último mandato do governo do Presidente Luis Inácio Lula da Silva para o início do governo Dilma Rouseff, a série vem decrescendo, permanecendo em queda até os dias de hoje.

Figura 2 – Apresenta-se a série original e a série em primeira diferença.

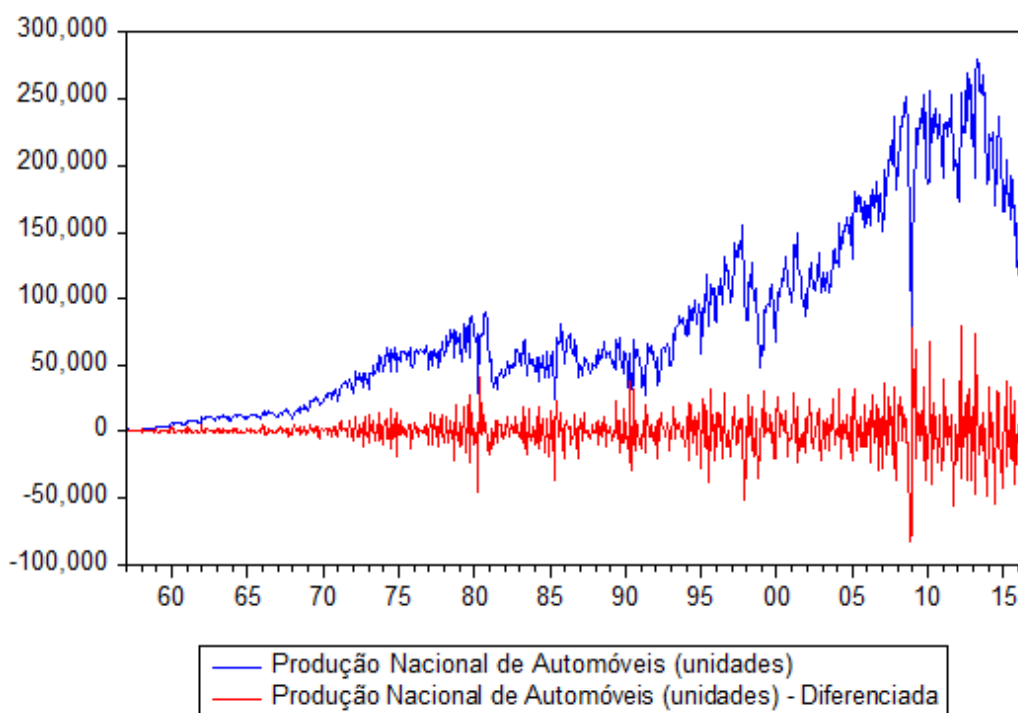


Figura 2 - Série original da Produção nacional de automóveis e série diferenciada

A Série Histórica da Produção Nacional de Automóveis tornou-se estacionária depois da aplicação de uma diferença ($d=1$). Após este período, no ano de 2008, a série apresenta instabilidade, o que pode ser encarado como um *cluster* de volatilidade, o que é um indicativo da aplicação de um modelo ARCH.

Com o intuito de verificar a estacionariedade da série e um possível modelo, faz-se FAC e FACP, conforme Figura 3, que, segundo a metodologia Box e Jenkins (1970), escolhe-se uma classe de modelo que melhor se ajuste na representação do ARIMA (p, d, q).

Figura 3 – FAC e FACP da série original

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.976	0.976	679.60	0.000
		2	0.964	0.229	1342.9	0.000
		3	0.953	0.086	1992.2	0.000
		4	0.944	0.066	2629.9	0.000
		5	0.941	0.174	3264.8	0.000
		6	0.934	-0.004	3891.1	0.000
		7	0.932	0.117	4515.7	0.000
		8	0.928	0.026	5135.7	0.000
		9	0.928	0.123	5756.2	0.000
		10	0.928	0.076	6377.9	0.000
		11	0.929	0.115	7002.5	0.000
		12	0.932	0.103	7632.3	0.000

Observa-se que na FAC a série não decai para zero, mostrando que a série é não estacionária, possivelmente, necessitará de diferenciações para torná-la estacionária. Pela FACP o modelo sugerido seria um autoregressivo.

Para determinar o grau de estacionariedade da série, aplicam-se os testes ADF e KPSS conforme Tabela 1.

Tabela 1 – Resultados apresentados pelos testes ADF e KPSS

	ADF ^a	KPSS ^b
Série em nível	-2,959112	2,652439
Série 1 ^a diferença	-34,37182	0,257565

Fonte: Elaborada pelos autores.

Notas: ^a Valores críticos de MacKinnon (1996): -3.493.129 (1%); -2.888.932 (5%) e -2.581.453 (10%).

^b Valores críticos de Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1): 0.739 (1%); 0.463 (5%) e 0.347 (10%).

Pelos testes realizados, observa-se que a série é não estacionária em nível mas, após uma diferença, a série torna-se estacionária com $d=1$.

A escolha pelo melhor modelo baseou-se pela minimização dos critérios penalizadores (menores valores de *AIC* e *BIC*), apresentados nas Tabelas 2, 3, 4 e 5.

Tabela 2 – Estimação dos modelos concorrentes para a Série Histórica da Produção Nacional de Automóveis

SARIMA (1,1,0) (1,0,0) ₁₂ - Equação da Média							
$d=1$	Parâmetro	Erro padrão	Estatística t	p valor	<i>AIC</i>	<i>BIC</i>	Ruído Branco
ϕ_1	-0,300048	0,019413	-15,45603	0,0000	21,80	21,82	Sim
ϕ_{12}	0,410827	0,021963	18,70561	0,0000			

Fonte: Elaborada pelos autores.

Tabela 3 – Estimação dos modelos concorrentes para a Série Histórica da Produção Nacional de Automóveis

SARIMA (1,1,1) (1,0,0) ₁₂ - Equação da Média							
$d=1$	Parâmetro	Erro padrão	Estatística t	p valor	<i>AIC</i>	<i>BIC</i>	Ruído Branco
ϕ_1	0,457179	0,034042	13,42982	0,0000	21,75	21,78	Sim
ϕ_{12}	0,39502	0,024131	16,37000	0,0000			
θ_1	-0,815533	0,025551	-31,91815	0,0000			

Fonte: Elaborada pelos autores.

Tabela 4 – Melhor modelo representativo da Série Histórica da Produção Nacional de Automóveis

SARIMA (1,1,0) (1,0,0) ₁₂ - Equação da Média							
$d=1$	Parâmetro	Erro padrão	Estatística z	p valor	<i>AIC</i>	<i>BIC</i>	Ruído Branco
ϕ_1	-0,386990	0,024537	-15,77163	0,0000	21,57	21,60	Sim
ϕ_{12}	0,340276	0,012256	27,76511	0,0000			

Fonte: Elaborada pelos autores.

Tabela 5 – Melhor modelo representativo da Série Histórica da Produção Nacional de Automóveis

ARCH (1,0) - Equação da Variância							
$d=1$	Parâmetro	Erro padrão	Estatística z	p valor	<i>AIC</i>	<i>BIC</i>	Ruído Branco
e	76835726	3086174	24,89676	0,0000	21,57	21,60	Sim
σ_{F-1}^2	0,863214	0,081109	10,64257	0,0000			

Fonte: Elaborada pelos autores.

Assim, o melhor modelo que representa a série é o modelo SARIMA (1,1,0) (1,0,0)₁₂ – ARCH(1), representado nas Tabelas 4 e 5, ressalta-se que estes modelos foram estimados de forma simétrica.

Nas Tabelas 2, 3, 4 e 5 são apresentados os parâmetros e estatísticas dos modelos concorrentes e do modelo escolhido para representar a série que, além de apresentar em seus resíduos as características de ruído branco, apresentou ainda as melhores estatísticas para os critérios penalizadores *AIC* e *BIC*, sendo este o melhor modelo ajustado.

O modelo melhor ajustado à série foi um modelo autoregressivo de ordem 1, com sazonalidade no lag 12, volatilidade e uma diferença: SARIMA (1,1,0) $(1,0,0)_{12}$ - ARCH(1).

O modelo selecionado representa que a produção de automóveis apresenta um comportamento autoregressivo de ordem 1, onde o mês anterior influencia a produção atual, com fator de influência negativo (-0,386990), mostrando um declínio nesta atividade. Também é captado um efeito de 12 meses, representado pelo parâmetro sazonal, com parâmetro (0,340276), mantendo-se ainda positivo, mas com valor inferior à dependência mensal.

Em relação à modelagem ARCH, o parâmetro σ_{t-1}^2 que representa a variância dos resíduos, com parâmetro (0,863214), revela um valor bastante alto, mostrando que haverá uma grande queda nos próximos períodos. Esta instabilidade representa que haverá mudanças na média do processo de produção futuro.

O exame dos resíduos, através das funções de autocorrelação e de autocorrelação, parcial oriundo do modelo selecionado apresenta-se não autocorrelacionados, não apresentando informações adicionais ao modelo, conforme pode ser observado na Figura 4.

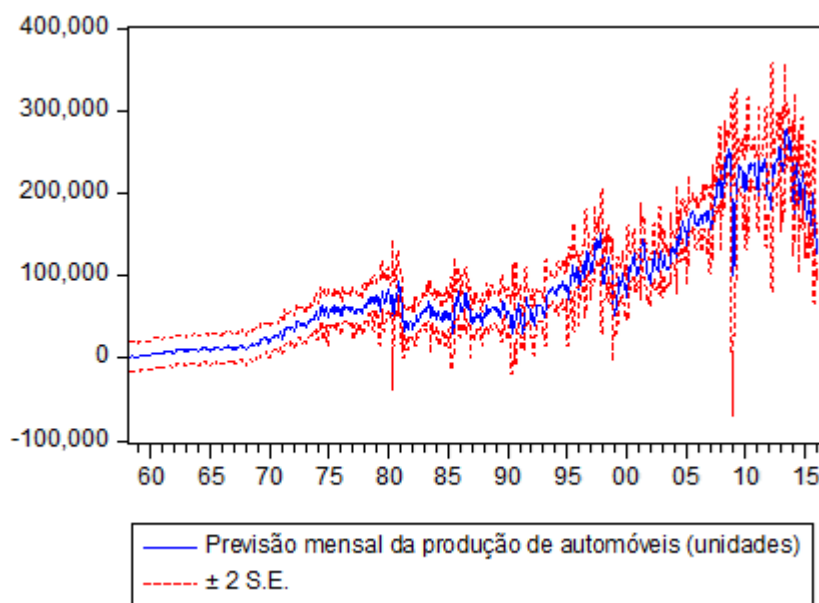
Figura 4 – FAC e FACP dos resíduos oriundos do modelo ajustado

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.040	0.040	1.1269	0.288
		2	-0.172	-0.174	21.843	0.000
		3	-0.082	-0.069	26.514	0.000
		4	-0.122	-0.151	36.931	0.000
		5	-0.008	-0.027	36.972	0.000
		6	-0.052	-0.113	38.859	0.000
		7	0.004	-0.021	38.872	0.000
		8	-0.025	-0.085	39.322	0.000
		9	-0.004	-0.025	39.331	0.000
		10	-0.010	-0.062	39.398	0.000
		11	0.033	0.015	40.172	0.000
		12	0.046	0.006	41.666	0.000

Uma vez que as estatísticas de validação do modelo foram adequadas, realizam-se previsões *in sample*, de modo a verificar o comportamento futuro da série, conforme Figura 5.

A Previsão da Série Histórica da Produção Nacional de Automóveis pode ser observada na Figura 5 e apresenta-se de acordo com a realidade, uma vez que o país está passando por uma grave crise econômica e, frente a esta realidade, a produção de automóveis tende a continuar em queda.

Figura 5 – Previsão mensal da produção nacional de automóveis



Para verificar a adequação dos modelos, foi realizada a análise dos resíduos, e também as estatísticas de previsão U-Theil, MAPE e EQM.

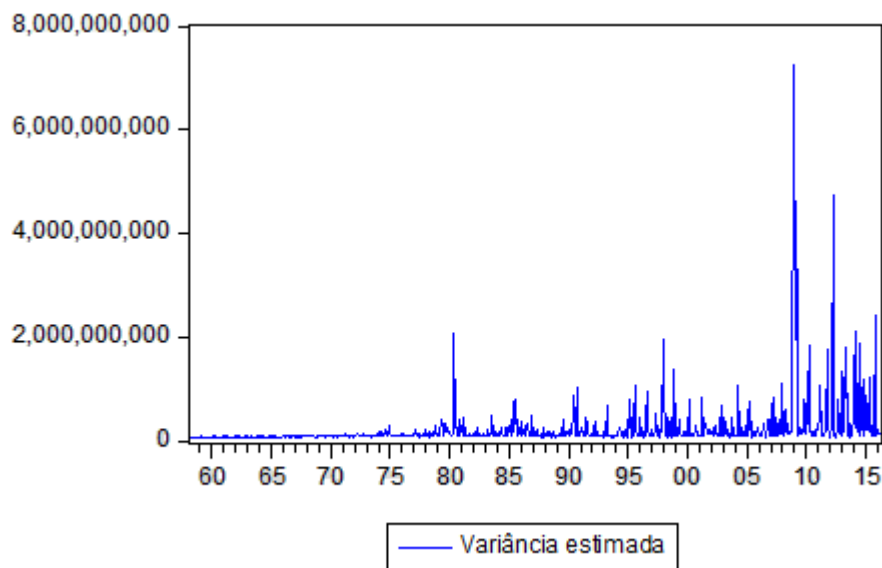
Para a estatística U-Theil, espera-se que seus valores variem entre 0 e 1 como indicação de modelos de previsão adequados, e seus melhores modelos são os que se aproximam de 0. O valor encontrado foi 0,060909, estando, portanto dentro do valor esperado.

O MAPE é a estatística mais utilizada, pois considera os erros em termos percentuais, e o valor da estatística gerado foi 10,99113 e do EQM foi 13310,43.

Na Figura 6, observa-se o gráfico do comportamento da volatilidade estimada pelo modelo linear – SARIMA(1,1,0)(1,0,0)₁₂ – ARCH(1), onde a volatilidade da série permanece estável, desde o início das observações. Após os anos 80, devido aos acontecimentos já mencionados anteriormente, ela se torna instável, mantendo-se assim até o período atual.

O valor do parâmetro no modelo ARCH σ_{t-1}^2 é igual a 0,863214, mostrando um alto valor de volatilidade da série, e a produção nacional de automóveis bastante instável, revelando uma incerteza futura neste ramo de atividade.

Figura 6 – Gráfico do comportamento da volatilidade estimada pelo modelo linear – SARIMA(1,1,0)(1,0,0)₁₂ – ARCH(1)



Assim, observa-se que o modelo está apto a realizar previsões, pois apresenta todas as condições necessárias para ser um modelo adequado. Verifica-se também que os valores previstos estão dentro do intervalo de confiança de 2 desvios-padrões. Com isso, as decisões a serem tomadas poderão se basear em bases científicas.

5 CONSIDERAÇÕES FINAIS

O processo gerador da série é um processo autoregressivo de ordem 1, com uma diferença necessária para tornar a série estacionária, com efeito sazonal no lag 12, apresentando ainda heterocedasticidade de ordem 1.

Com o modelo ajustado, foi possível a realização de previsões *in sample*. Neste estudo, verificou-se o comportamento da média condicional, representado por um modelo ARIMA e o comportamento da variância condicional à média do processo, com a utilização dos modelos autoregressivos condicionais à heterocedasticidade – ARCH.

A série continua com um decaimento nas previsões, com queda. Este fato é corroborado pois, a partir de março de 2016, vem ocorrendo quedas frequentes, sendo que neste mesmo mês (março de 2016), a queda foi em torno de 18%. Desta forma, a metodologia empregada foi eficaz em captar os movimentos da série. Deixa-se como sugestões para estudos futuros a utilização de outras técnicas de previsão, assim como o emprego da metodologia à produção de autoveículos.

Agradecimentos

Agradecemos ao LAME – Laboratório de Análise e Modelagem Estatística da Universidade Federal de Santa Maria – UFSM, pelo espaço utilizado, assim como softwares e equipamentos.

REFERÊNCIAS

ARÊDES, A. F; PEREIRA, M. W. G. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no estado do Paraná. **Revista de Economia Agrícola**, vol. 55, n. 1, p. 63-76, jan./jun. 2008.

ASSOCIAÇÃO NACIONAL DOS FABRICANTES DE VEÍCULOS AUTOMOTORES – ANFAVEA Disponível em: <http://www.anfavea.com.br/tabelas.html>. (acesso em março / 2016).

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

BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 31, p. 307-327, 1986.

BUENO, R. L. S. **Econometria de Séries Temporais**. 1. ed. São Paulo: Cengage Learning, 2008.

CAMPOS, K. C. Análise da volatilidade de preços de produtos agropecuários no Brasil. **Revista de Economia de Agronegócio**, vol. 5, n. 3, p. 303-327, 2007.

ENDERS, W. **Applied econometric time series**. New York: Wiley, 1995

GUARNIERI, J.; 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 e Jenkins. In: XXIX Encontro Nacional De Engenharia De Produção, Enegep. **Anais...** Salvador, BA, p. 1-14, out. 2009.

GUJARATI, D. N. **Econometria Básica**. Macron Books, São Paulo: Pearson Education do Brasil, 2000.

HAMILTON, J. D. **Time series analysis**. Princeton University Press, Princeton: NJ, 1994.

KIRCHNER, R. M; SOUZA, A. M; STUMM, E. M. F. A modelagem como ferramenta de gestão. **LAJBM Latin American Journal of Business Management**, vol. 2, n. 1, p. 2-23, jan./jun. 2011.

KLIDZIO, R. **Modelos de Previsão Aplicados ao Controle de Qualidade Com Dados Autocorrelacionados**. 154 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria. 2009.

MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA E COMÉRCIO EXTERIOR – MDIC (acesso em fevereiro / 2016). Disponível em: <http://www.mdic.gov.br/sitio/interna/interna.php?area=2&menu=327>.

MORETTIN, P. A. **Econometria Financeira**. São Paulo, 2008.

MORETTIN, P. A; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Edgard Blücher, 2006.

PATTERSON, K. **An Introduction to Applied Econometrics: A Time Series Approach**. New York: St. Martin's Press, 2000.

SAMOHYL, R. W.; SILVA, W. V.; FIGUEIREDO, J. N.; ARAÚJO, F. P. O uso da análise de intervenção em séries temporais Univariadas: uma aplicação empírica no mercado automobilístico brasileiro. In: XXXIV SBPO Simpósio Brasileiro De Pesquisa Operacional, **Anais...** Rio de Janeiro, Rio de Janeiro, nov. 2002.

SILVA, W. S; SÁFADI, THELMA E CASTRO JÚNIOR, L. G. Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja. **Revista de Economia e Sociologia Rural**, v. 43, n. 1, p. 1-16, 2005.

SOUZA, A. M; SOUZA, F. M; ZANINI, R. R; REICHERT, B; LIMA JUNIOR, A. V. Applications Residual Control Charts Based on Variable Limits. **IJERA Int. Journal of Engineering Research and Applications**, vol. 5, issue 5, part-1, p. 44-50, may 2015.

SOUZA, F. M; SOUZA, A. M; MENEZES, R. Análise Empírica do Número de Consumidores e do Consumo de Energia Elétrica no Rio Grande do Sul por meio de Modelos Matemáticos. **Revista Espacios**, vol. 34, vol. 1, 2013.

WALTER, O. M. F. C. *et al.* Previsão de vendas para um modelo de automóvel popular com a metodologia Box e Jenkins. In: X SEPROSUL – Semana De Engenharia De Produção Sul-Americana. **Anais...** Chile, Santiago, p. 1-10, nov. 2010.

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

VAL, V. C; CORRÊA, V. P. Volatilidade dos fluxos de capitais do balanço de pagamentos brasileiro: uma análise por meio do modelo ARCH (Modelo Auto-Regressivo com Heterocedasticidade Condicional). In: XXXIV Encontro Nacional De Economia Da Anpec – Associação Nacional Dos Centros De Pós-Graduação Em Economia. **Anais...** 2006.

VASCONCELLOS, R. M. G. **Reconstrução de espaços de estados aeroelásticos por decomposição em valores singulares**. 127 f. Dissertação (Mestrado em Aeronaves) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2007.

Como Referenciar este Artigo, conforme ABNT:

MARASCA, L; SOUZA, A. M. O Efeito das Crises Econômicas Mundiais na Volatilidade da Produção de Automóveis no Brasil. **Rev. FSA**, Teresina, v.13, n.6, art.5, p. 71-90, nov./dez. 2016.

Contribuição dos Autores	L. Marasca	A. M. Souza
1) concepção e planejamento.	X	X
2) análise e interpretação dos dados.	X	X
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X
4) participação na aprovação da versão final do manuscrito.	X	X