

Área: Teoria Aplicada

ÍNDICE DE INTENÇÃO DE CONSUMO DAS FAMÍLIAS (ICF): UMA ESTIMAÇÃO POR MEIO DO MODELO ARIMA

José Eduardo de Melo Barros

Mestrando no Programa de Pós-Graduação em Administração e Desenvolvimento Rural da Universidade Federal Rural de Pernambuco – PADR/UFRPE

E-mail: jeduardobarros@hotmail.com

Endereço: Rua Luiz Pimentel, 325. Boa Viagem. Recife - PE. CEP: 51030-350

Telefone: (81) 98865-5071

André de Souza Melo

Doutor em Economia - Universidade Federal de Pernambuco

Professor Adjunto da Universidade Federal Rural de Pernambuco

Coordenador do Programa de Pós-Graduação em Administração e Desenvolvimento Rural – PADR/UFRPE

Alessandra Carla Ceolin

Doutora em Agronegócios - Universidade Federal do Rio Grande do Sul

Professora Adjunta da Universidade Federal Rural de Pernambuco

Coordenadora do Curso de Bacharelado em Administração da Universidade Federal Rural de Pernambuco

ÍNDICE DE INTENÇÃO DE CONSUMO DAS FAMÍLIAS (ICF): UMA ESTIMAÇÃO POR MEIO DO MODELO ARIMA

RESUMO

O presente trabalho teve por objetivo desenvolver um modelo autorregressivo ARIMA capaz de fazer estimações para o índice de Intenção de Consumo das Famílias (ICF), bem como prever as doze próximas observações futuras da série. Foi coletada, junto às publicações da Confederação Nacional do Comércio de Bens, Serviços e Turismo (CNC), a série temporal mensal do ICF nacional, compreendendo o período entre janeiro de 2010 e julho de 2015, totalizando uma amostra de 67 observações. A metodologia obedeceu estritamente às quatro fases propostas por Box & Jenkins (1976): diagnóstico, estimação, avaliação e previsão. Com base nos resultados obtidos, concluiu-se que o modelo ARIMA (1,1,15) referente à estimação ICF foi eficiente e apresentou projeções satisfatórias para previsão do índice. Tal alegação se deve ao fato de que a hipótese nula de que resíduos se comportam como um ruído branco não pôde ser rejeitada, assim como o modelo apresentou erro quadrado médio baixo e capacidade de previsão adequada e elevada significância dos coeficientes estimados.

Palavras chave: Séries temporais. Previsão de índice. Modelo ARIMA. Modelo Box-Jenkins. Intenção de Consumo das Famílias.

Classificação JEL: C1; D1

FAMILY CONSUME INTENT INDEX (ICF): AN ESTIMATE THROUGH ARIMA MODEL

ABSTRACT

The present study had the goal of develop an autoregressive model ARIMA, capable of making estimations for the Family Consume Intent Index (ICF) and predict the twelve future observations of the series. It was collected on National Confederation of Trade in Goods, Services, and Tourism (CNC) publishing the monthly temporal series of national ICF, comprehending January of 2010 to July of 2015, with a total of 67 sample of observations. The methodology followed strictly to the four phases proposed by Box & Jenkins (1976): identification, estimation, diagnostic checking and forecast. Based on the results obtained, it was concluded that the ARIMA model (1,1,15) for the estimation ICF was efficient and presented projections for satisfactory index forecast . Such a claim is due to the fact that the null hypothesis that residues behave like a white noise could not be rejected, as well as model presented mean squared error low and adequate predictability and high significance of the estimated coefficients.

Keywords: Time series. Index forecasting. ARIMA model. Box-Jenkins models. Family Consume Index.

1. Introdução

O consumo das famílias brasileiras mantém considerável regularidade, no que se refere à sua proporção do Produto Interno Bruto (PIB), atingindo o patamar médio de 60%

(IPEA, 2007). Ainda segundo o IPEA (2007), faz-se necessário o monitoramento e o estudo aprofundado desta temática, dada a sua importância para a economia.

Nesse sentido, a Confederação Nacional do Comércio de Bens, Serviços e Turismo (CNC), produz o indicador de Intenção de Consumo das Famílias, com vistas a mensurar, com fidedignidade, a avaliação que os consumidores fazem em relação aos aspectos da condição de vida de sua família. Trata-se de um índice antecedente do consumo, que verifica questões como capacidade de consumo (atual e de curto prazo), nível de renda doméstico, segurança no emprego e qualidade de consumo, presente e futuro (CNC, 2015).

A pesquisa de ICF possui uma variância de 0 a 200 pontos, onde são verificados o grau de satisfação e insatisfação dos consumidores. De acordo com os critérios do estudo, quando o índice se acima de 100 pontos, entende-se que os as famílias estão satisfeitas em termos de emprego, renda e capacidade de consumo, ao passo que a percepção de insatisfação, advém quando o índice está abaixo do limiar de 100 pontos.

O índice é gerado a partir de sete itens, os quais também se utilizam de escalas de 0 a 200. Quatro destes itens, ou seja, “emprego atual”, “renda atual”, “compra a prazo” e “nível de consumo atual” compreendem a expectativa das famílias em relação estes itens no ano anterior. Os outros três itens dizem respeito a perspectivas futuras, em relação “à melhoria profissional para os seis meses seguintes”, “às expectativas de consumo para os três meses seguintes” e “à avaliação do momento atual quanto à aquisição de bens duráveis”.

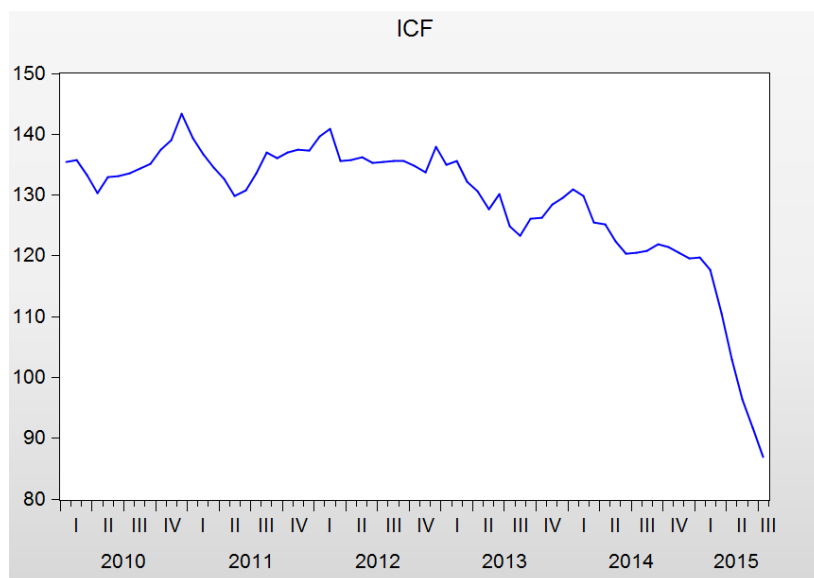


Figura 1: Série ICF (jan/2010 a jul/2015)

Fonte: desenvolvido pelo autor com dados da pesquisa

O estudo mantém uma série mensal desde janeiro de 2010, aplicando 18 mil questionários em todas as unidades da Federação (CNC, 2015). A figura 1 apresenta a série histórica do ICF, desde a primeira verificação até julho de 2015. Depreende-se que a série mantinha regularidade no comportamento até o primeiro trimestre de 2014, quando iniciou uma tendência de queda. O mês de outubro de 2014 é o último pico de crescimento da série, que apresenta desde então uma queda acintosa em sua curva. Cabe também ressaltar que até maio de 2015 o índice nunca havia ultrapassado o limiar de 100 pontos, mas vem apresentando recordes negativos desde então.

A conjuntura atual denota uma perspectiva cautelosa para o consumo. A inflação oficial, medida pelo IPCA, registrou 0,79% em junho, ao passo que já havia registrado 0,74% em maio. Trata-se de um pico, não registrado desde 1996, quando o índice de inflação atingiu 1,19% (IBGE,2015). Ainda de acordo com os dados do IPCA, três grupos foram os maiores

responsáveis pelo aumento no índice: alimentação e bebidas, habitação e transporte. Estes grupos compreendem 71% do IPCA, o que representa grande impacto no orçamento das famílias.

Nesse contexto de incertezas e pessimismos, e considerando a representatividade da temática na economia, faz-se necessário o estudo de previsão de cenários, capazes de produzir informações relevantes e auxiliar na tomada de decisão. Bastante referendados, os modelos econométricos são apropriados para, dentre outros recursos, realizar previsões em séries temporais. Em consonância a isso, este trabalho tem por objetivo desenvolver um modelo autorregressivo ARIMA capaz de fazer estimativas para a série do ICF, bem como prever as doze próximas observações futuras do índice.

2. Referencial Teórico

Previsões de demanda são produzidas a partir de métodos quantitativos, qualitativos ou mesmo com o arranjo entre ambos. Os métodos quantitativos são denominados de *forecasting*, sobre os quais se lastreiam as análises de séries temporais, ou seja, as previsões buscam identificar a variação destas demandas dentro de determinado intervalo de tempo (FOGLIATTO, 2003).

Uma série no tempo pressupõe que haja um modelo de descrição da natureza aleatória do processo que produziu a série de observações estudada (PINDYCK E RUBINFELD, 2004). A proposição de modelos, ainda de acordo com os autores, é que as observações da série de dados são advindas de modo aleatório para uma distribuição de probabilidade, competindo ao modelador analisar os aspectos dessa aleatoriedade para fundamentar um modelo de previsão. Os modelos que possuem apenas uma série temporal são denominados de modelos univariados (FAVA, 2000).

Segundo Pindyck e Rubinfeld (2004), no processo de realização de previsões, é necessário identificar se o processo estocástico que originou a série não possui variação ao longo do tempo, ou seja, avaliar se tal processo não pode ser considerado estacionário. Segundo os mesmos autores, se for observada esta característica, é necessário modelá-lo por meio de uma equação com coeficientes fixos, que conseguem ser estimados considerando os dados passados, uma vez que se presume que, ao longo do tempo, as suas características estocásticas não se alterem. Todavia, em se considerando que o processo não é estacionário, é necessário desenvolver a estacionariedade através de diferenciações dos dados da série.

De acordo com Farias e Sáfadi (2010), considerando que a série é estacionária, tem-se, para qualquer observação, que sua média, variância e covariância apresentam estacionariedade. Os autores apontam que, para desenvolver um modelo com processo estocástico, a função de auto-correlação (FAC), que demonstra a interdependência entre pontos subsequentes da série Y_t , é um fator preponderante para análise.

De acordo com Pindyck e Rubinfeld (2004), deve-se, através do teste estatístico Q de *Box-Pierce*, demonstrar que os coeficientes de correlação são zero, e, desta maneira, a série é estacionária. Outra forma de se observar a estacionariedade ou não de uma série, ou identificar o número de vezes que a série deve ser diferenciada para tornar-se estacionária, é através da análise gráfica das funções de auto-correlação desenvolvidas nas diferenciações.

Uma série pode ser considerada estacionária, na medida em que sua função de autocorrelação sofre defasagens (lags). Tenciona-se que a série assuma a forma de “ruído branco” (GUJARATI, 2000). Makridakis et al. (1998) delimitam a forma “ruído branco” como um modelo ARIMA (0,0,0) uma vez que, neste caso, inexistente a parte autorregressiva (AR), ou seja, todos os termos Y_t da série são independentes dos termos Y_{t+1} . Também, de acordo com os autores, não existe neste modelo diferenciação alguma, assim como a parte de médias móveis (MA), tendo em vista que todos os termos da série Y_t não dependeria dos erros e_{t-1} .

De acordo com Morettin e Toloí (2004), os modelos Box–Jenkins têm a capacidade de descrever o comportamento das séries que rejeitam a hipótese de não correlação entre os erros. Nesse sentido, os modelos ARIMA conseguem caracterizar dois tipos de processos. Os **lineares estacionários**, calcados em três processos (autorregressivo AR; de ordem p , processo de médias móveis MA de ordem q ; e processo autorregressivo e de médias móveis ARMA, de ordem p e q); e processos **lineares não estacionários homogêneos**, que, segundo Morettin e Toloí (2004), supõem que não há estacionariedade nas séries em nível e/ou inclinação. Nesse sentido, deve-se aplicar um número determinado de diferenciações entre suas observações para alcançar tornar a série estacionária, processo que normalmente demanda uma ou duas defasagens.

Pindyck e Rubinfeld (2004) classificam que o quantitativo de vezes em que a série original tem de sofrer diferenciação antes de culminar em uma série estacionária é tido como ordem de homogeneidade ou de integração. Tais processos são descritos pelos modelos autorregressivos p , pela ordem de integração d (número de diferenciações) e pelas médias móveis q , resultando no modelo ARIMA (p, d, q), que também podem incluir um operador de sazonalidade (s_1, s_2, s_3) (Morettin & Toloí, 2004).

Para Fisher (1982), os modelos ARIMA são capazes de descrever, de forma satisfatória, séries estacionárias e não-estacionárias, desde que o seu comportamento não seja explosivo, ou seja, uma manifestação de forte tendência ascendente (quase verticalmente), que também pode ser denominada de comportamento de estacionariedade homogênea.

Os modelos determinados por Box-Jenkins (1976) compreendem: Modelos de Médias Móveis (MA), Modelos Autorregressivos (AR), Modelo Misto Autorregressivo e de Médias Móveis (ARMA) e Modelo Misto Autorregressivo e de Médias Móveis para processos não estacionários homogêneos (ARIMA).

2.1 Modelos de Médias Móveis (MA)

Pindyck e Rubinfeld (2004, p. 586) afirmam que “no processo de médias móveis de ordem q , cada observação de Y_t é gerada por uma média ponderada de perturbações aleatórias que vão para trás q períodos”. Makridakis et al. (1998), de maneira análoga, apontam que a relação de dependência entre os erros e a equação é denominada MA. Nesse sentido, o termo MA pode ser definido pela média móvel dos erros ε . O processo MA (q) é representado na equação 1:

$$Y_t = \mu + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2} - \dots - \theta_q\varepsilon_{t-q} \quad (1)$$

Segundo Makridakis et al. (1998), os parâmetros $\theta_1, \theta_2, \dots, \theta_q$ são determinadores das ponderações da média móvel, os quais podem ser positivos ou negativos. Tais modelos partem da premissa de que cada termo de perturbação ε_t é uma variável aleatória normalmente distribuída, com média zero, variância constante e covariância igual a zero, ou seja, pressupõem que as aleatoriedades das perturbações se configuram um ruído branco.

2.2 Modelos Auto-Regressivos (AR)

Pindyck e Rubinfeld (2004) definem o processo autorregressivo de ordem p como a observação de Y_t que é produzida por uma média ponderada de observações do passado que recua p períodos de tempo, concomitantemente a uma perturbação aleatória no período corrente. O processo AR (p) pode ser descrito pela equação 2:

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \delta + \varepsilon_t \quad (2)$$

Tem-se que δ é um termo constante que se relaciona com a média do processo estocástico. Nesse sentido, espera-se que a soma dos parâmetros $\phi_1 + \phi_2 + \dots + \phi_p$ deve ser inferior a 1 para que o processo seja considerado estacionário. Bacci et al (2006) consideram que haverá estacionariedade no modelo se a variância de Y_t for constante e as autocovariâncias independentes de t (tempo).

2.3 Modelo Auto-Regressivo e de Médias Móveis (ARMA)

Makridakis et al. (1998) afirmam que processos aleatórios estacionários possuem características autorregressivas e de médias móveis, permitindo a modelação por meio de um processo misto autorregressivo e de médias móveis ARMA (p, q). Os autores ainda explicam que, em função dos valores de p e q , Y_t é variável dependente dos p valores passados de Y e dos q valores passados dos erros ε . Esse processo pode ser identificado pela equação 3:

$$Y = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \delta + \varepsilon_t - \phi_1 \varepsilon_{t-1} - \phi_2 \varepsilon_{t-2} - \dots - \phi_q \varepsilon_{t-q} \quad (3)$$

Pindyck e Rubinfeld (2004) afirmam que a pressuposição é de que esse processo seja estacionário, ou seja, possua a média constante ao longo do tempo. Nesse sentido, considera-se que a soma $\phi_1 + \phi_2 + \dots + \phi_p$ seja inferior a 1.

2.3 Modelo Autorregressivo e de Médias Móveis para processos não estacionários homogêneos (ARIMA)

Considerando Pindyck e Rubinfeld (2004) e Fava (2000), séries não estacionárias são capazes de serem transformadas em estacionárias na medida em que suas observações são diferenciadas em primeira ou mais ordens. A equação 4 demonstra uma primeira diferenciação.

$$Z_t = \Delta Y_t = Y_t - Y_{t-1} \quad (4)$$

Onde:

Y_t = observação Y , no período t da série Y_T sem diferenciação;

Y_{t-1} = observação Y , no período $t-1$ da série Y_T sem diferenciação;

$\Delta Y_t = Z_t$ = observação Z , no período t , pertencente à série Z_T com dados da série Y_T diferenciados em primeira ordem.

A primeira diferenciação da série se dá com o valor da segunda observação sendo diminuída da primeira; a terceira sendo diminuída da segunda; a quarta da terceira e assim sucessivamente. Com isso, a série diferenciada em primeira ordem, Z_t , possuirá menos uma observação ($n-1$ observações) que a série original Y_t (Bacci et al,2006).

De maneira análoga, a série Y_t diferenciada de segunda ordem, ou a série Z_t diferenciada em primeira ordem, origina a série W_t . Esta série diferenciada duas vezes (W_t) tem $n-2$ observações em comparação com a série original Y_t . A equação 5 demonstra a segunda diferenciação dos dados.

$$W_t = \Delta^2 Y_t = \Delta(\Delta Y_t) = \Delta(Y_t - Y_{t-1}) \quad (5)$$

Nesse sentido, sofrendo uma ou mais diferenciações para alcançar a estacionariedade, a série Y_t origina a série estacionária W_t , cuja modelação se dá com um processo ARIMA (p, d, q). Segundo Pindyck e Rubinfeld (2004), esse processo autorregressivo, integrado em uma ou mais ordens e de médias móveis, de ordem (p, d, q), pode ser escrito através da equação 6.

$$\phi(B)\Delta^d Y_t = \delta + \theta(B) \varepsilon_t \quad (6)$$

Onde:

$$\Delta^d Y_t = W_t;$$

d = ordem da série estacionária W_t , ou seja, o número de vezes que a série não estacionária Y_t foi diferenciada até se tornar à série estacionária W_t ;

$\phi(B)$ = operador auto-regressivo;

$\theta(B)$ = operador de médias móveis;

$\Delta = 1 - B$, onde o operador B determina uma diferenciação no tempo de um período em cada circunstância que seja aplicado a uma variável Y_t .

Por fim, de acordo com Morettin e Toloi (2004), a montagem de um modelo ARIMA é lastreada em um ciclo com algumas fases: identificação de uma classe geral de modelos que será analisada; especificação do modelo, com base na análise de auto-correlações, auto-correlações parciais e outros critérios; estimação dos parâmetros do modelo; verificação do modelo ajustado, que é realizada através de uma análise de resíduos para medir sua adequação para realizar a previsão; e, se o modelo não for ajustado, o ciclo se repete a partir da identificação do modelo. Estas fases são definidas dentro da metodologia utilizada neste trabalho.

3 Procedimentos Metodológicos

A metodologia de Box & Jenkins (1976), amplamente difundida na literatura para formulação de um modelo ARMA, ARIMA ou SARIMA, foi adotada neste estudo como procedimento metodológico para a predição do Índice de Consumo das Famílias. Como visto, são quatro estágios, os quais explicam esta pesquisa e são amplamente destrinchados adiante.

Na fase de **Identificação**, verificou-se a ordem d do modelo por meio do teste de raiz unitária, verificada com o teste de Dickey-Fuller Aumentado (ADF), que determinou a ordem de integração das variáveis consideradas. O teste ADF, segundo Seddighi et al. (2000), testa as hipóteses de $H_0 = 0$, onde há raiz unitária e portanto a série não é estacionária, e $H_a < 0$, onde a série seria estacionária.

De acordo com Farias e Sáfiadi (2010), há três critérios estatísticos mais recorrentes, quais sejam: Akaike (AIC), para séries com menos de 100 observações; Schwarz-Bayesiano (BIC) e Hannan-Quinn (HQ), para séries acima de 100 observações. Tais testes foram utilizados nesta pesquisa e são representados por meio das seguintes equações:

$$AIC(k) = \ln |\Sigma\mu(p)| + 2/T \times pn^2 \text{ (Akaike)} \quad (7)$$

$$BIC(k) = \ln |\Sigma\mu(p)| + \ln T/T \times pn^2 \text{ (Schwarz)} \quad (8)$$

$$HQ(k) = \ln |\Sigma\mu(p)| + \ln \ln T/T \times pn^2 \text{ (Hannan-Quinn)} \quad (9)$$

O estágio de **estimação** consiste em definir os parâmetros dos termos autorregressivos e de média móvel a serem incluídos no modelo. Dentro desta fase, fez-se a análise dos correlogramas, os quais apresentaram, a partir das funções de Autocorrelação (q) e de Autocorrelação Parcial (p), as ordens de Média Móvel e Autorregressiva, respectivamente. A observância do número de defasagens d da série e a composição das ordens de Média Móvel e Autorregressiva configuraram-se na estimação do modelo ARIMA (p, d, q).

De acordo com Gujarati (2000), a **avaliação** tem por função verificar se o modelo identificado é adequado para os fins que se propõe considerando o comportamento dos resíduos estimados pelo modelo, através da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP). Por meio do teste de Ljung-Box, considerou-se, portanto, que

o modelo mais ajustado não deveria rejeitar a hipótese nula de que os resíduos têm comportamento de ruído branco, ou seja, suas autocorrelações se manifestam de forma aleatória e não são significativas. Nesse sentido, também se desenvolveu, a partir do modelo adotado, uma estimação comparativa com observações que já existiam, ou seja, uma previsão *ex-post*, a fim de verificar o ajuste do modelo.

Na etapa de **previsão**, verifica-se a confiabilidade da predição do modelo adotado. Santos e Lima (2006) recomendam que a amostra não deve possuir menos de 50 observações; assim como a série tem de ser homocedástica, ou seja, sua variância deve ser uniforme ao longo do tempo; e, também, deve ser estacionária, que representa variar em torno de uma média e de uma variância constante.

Na fase de previsão, optou-se por verificar inicialmente 6 observações futuras. No entanto, em função de a série estimada apresentar variação de comportamento na sexta observação, concluiu-se a estimação em 12 observações de meses subseqüentes (agosto de 2015 a julho de 2016), a fim de avaliar esta variação na tendência de queda e a própria capacidade do modelo utilizado para predições mais extensas.

Ressalta-se, então, que se trata de uma pesquisa de natureza quantitativa, trabalhada estatisticamente com os pacotes Eviews 12 e Estima Rats. Foi utilizada, portanto, a série da Intenção de Consumo das Famílias (ICF) com todas as observações disponíveis, ou seja, o índice desde o seu surgimento – janeiro de 2010 – até a sua última observação – julho de 2015, cujos resultados apresentam-se a seguir.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 Procedimento de Identificação

Como disposto na metodologia de Box & Jenkins (1976), a prova de estacionaridade é o primeiro passo para elaboração de modelos ARIMA. Ao utilizar o Teste Dickey-Fuller Aumentado (ADF), constatou-se que a série é estacionária em primeira ordem de diferenciação, uma vez que a série diferenciada não possui raiz unitária. Verifica-se, pelo Quadro 1, que é possível rechaçar a hipótese nula de que a série diferenciada não é estacionária, tendo em vista que a probabilidade é estatisticamente significativa (inferior a 0,05). Considerando que a série foi integrada de ordem 1, tem-se que o valor de *d*, para este modelo, é igual a 1, de modo que se caracteriza o modelo linear ARIMA.

Null Hypothesis: D(ICF) has a unit root		
Exogenous: Constant		
Lag Length: 0 (Automatic - based on SIC, maxlag=10)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.416917	0.0000
Test critical values:	1% level	-3.534868
	5% level	-2.906923
	10% level	-2.591006
*MacKinnon (1996) one-sided p-values.		

Quadro 1: Teste de estacionaridade da série ICF diferenciada em 1ª ordem

Fonte: desenvolvido pelos autores com dados da pesquisa

4.2 Procedimento de estimação do modelo identificado

Observando-se a Função de Autocorrelação (q) e a Função de Autocorrelação Parcial (p), dispostas na figura 2, tem-se, por indicação visual, analisando os valores fora do intervalo

de confiança (picos), que a Média Móvel (MA) deve seguir até a 6ª ordem e o modelo linear Autorregressivo deve ter ordem 2.




Figura 2: Função de Autocorrelação (q) e Função de Autocorrelação Parcial (p)
Fonte: desenvolvido pelos autores com dados da pesquisa

A estimação inicial foi desenvolvida a partir dos parâmetros AR = 2 e MA 6, com o teste de BOXJENK. Observou-se, como demonstra o Quadro 2, que não há significância a 5% para os parâmetros estabelecidos, uma vez que a constante e a média móvel superam este critério.

Dependent Variable: D(ICF)				
Method: Least Squares				
Date: 08/06/15 Time: 16:51				
Sample (adjusted): 2010M04 2015M07				
Included observations: 64 after adjustments				
Convergence achieved after 6 iterations				
MA Backcast: 2009M10 2010M03				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.732172	0.414653	-1.765746	0.0824
AR(2)	0.270903	0.127879	2.118428	0.0382
MA(6)	-0.095788	0.151986	-0.630243	0.5309
R-squared	0.078141	Mean dependent var		-0.724219
Adjusted R-squared	0.047916	S.D. dependent var		2.664035
S.E. of regression	2.599427	Akaike info criterion		4.794200
Sum squared resid	412.1781	Schwarz criterion		4.895397
Log likelihood	-150.4144	Hannan-Quinn criter.		4.834067
F-statistic	2.585327	Durbin-Watson stat		1.503986
Prob(F-statistic)	0.083611			
Inverted AR Roots	.52	-.52		
Inverted MA Roots	.68	.34+.59i	.34-.59i	-.34-.59i
		-.34+.59i	-.68	

Quadro 2: Estatísticas do modelo estimado ARIMA (2,1,6)
Fonte: desenvolvido pelos autores com dados da pesquisa

Identificou-se, também, conforme demonstra a figura 3, que a linha de tendência demonstra um desajuste em uma previsão ex-post para os valores de (q = 6) e (p = 2), ou seja, na predição para os últimos seis meses observados (fevereiro a julho), verifica-se visualmente que o modelo não é adequado.




Figura 3: Previsão ex-post para o modelo estimado ARIMA (2,1,6)
 Fonte: desenvolvido pelos autores com dados da pesquisa

Em função da inadequação apresentada pelo modelo previamente estipulado, considerou-se, na seleção de um modelo mais ajustado, o princípio de parcimônia, observando a significância dos parâmetros, o comportamento dos resíduos e os critérios de informação de Akaike (AIC) e Schwarz (SCH). Verificou-se que o modelo ARIMA (1,1,15), possui um erro quadrado médio bastante baixo, da ordem de 6,40, ao passo que os coeficientes também são significativos, conforme demonstra o quadro 3.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.964204	0.384088	-2.510376	0.0147
AR(1)	0.522842	0.114493	4.566601	0.0000
MA(15)	-0.874843	0.028203	-31.01995	0.0000
R-squared	0.500019	Mean dependent var		-0.752000
Adjusted R-squared	0.483891	S.D. dependent var		2.652614
S.E. of regression	1.905657	Akaike info criterion		4.172586
Sum squared resid	225.1549	Schwarz criterion		4.272942
Log likelihood	-132.6090	Hannan-Quinn criter.		4.212183
F-statistic	31.00238	Durbin-Watson stat		2.204597
Prob(F-statistic)	0.000000			
Inverted AR Roots	.52			
Inverted MA Roots	.99	.91-.40i	.91+.40i	.66+.74i
	.66-.74i	.31+.94i	.31-.94i	-.10+.99i
	-.10-.99i	-.50+.86i	-.50-.86i	-.80+.58i
	-.80-.58i	-.97+.21i	-.97-.21i	

Quadro 3: Estatísticas do modelo ajustado ARIMA (1,1,15)
 Fonte: desenvolvido pelos autores com dados da pesquisa

O modelo ARIMA (1,1,15) demonstra-se ajustado em uma previsão *ex-post*, como se observa na figura 3 a linha de tendência, assim como a tabela 1 corrobora numericamente com esse ajuste, a um nível de confiança de 95%.

Tabela 1: Previsão *ex-post* da Intenção de Consumo das Famílias (ICF)

Mês	ICF (real)	ICF (prev. <i>ex post</i>)
Fevereiro	117.7640009433	116.8805768970
Março	110.5618576110	111.8643583207
Abril	102.9000000000	105.3193363181
Mai	96.4000000000	100.0157019588
Junho	91.7000000000	95.2916100279
Julho	86.9000000000	89.3760410502

Fonte: Desenvolvido pelos autores de acordo com os dados da pesquisa

4.3 Procedimento de Avaliação

Utilizando o teste de Ljung-Box, para os coeficientes de MA = 15 e AR = 1, tem-se as autocorrelações dos resíduos com os seus valores no passado, conforme tabela 2. Observando-se o nível de significância destas correlações, não é possível rejeitar a hipótese nula de que há ruído branco, uma vez que para quase a totalidade das correlações inexistem significância a 5%.

Tabela 2: Teste de Ljung-Box para autocorrelação dos resíduos

Defasagens	FAC	PAC	Q-Stat	Prob
1	-0.138	-0.138	1.2913	
2	0.212	0.197	4.4023	
3	-0.106	-0.059	5.1980	0.023
4	0.056	-0.003	5.4232	0.066
5	-0.093	-0.059	6.0534	0.109
6	-0.049	-0.086	6.2324	0.182
7	-0.062	-0.047	6.5210	0.259
8	-0.177	-0.187	8.9199	0.178
9	-0.087	-0.127	9.5077	0.218
10	0.017	0.052	9.5310	0.299
11	0.077	0.097	10.008	0.350
12	0.074	0.074	10.462	0.401
13	0.176	0.164	13.051	0.290
14	0.020	0.013	13.084	0.363
15	-0.001	-0.089	13.084	0.441
16	0.103	0.084	14.035	0.447
17	0.036	0.055	14.154	0.514
18	-0.312	-0.367	23.179	0.109
19	-0.058	-0.114	23.496	0.134
20	-0.034	0.174	23.607	0.168
21	-0.071	-0.009	24.111	0.192
22	0.030	0.064	24.204	0.234
23	-0.082	-0.095	24.906	0.251
24	0.120	0.046	26.440	0.233
25	-0.088	-0.033	27.281	0.244
26	0.106	-0.152	28.543	0.238
27	0.111	0.059	29.960	0.226
28	-0.062	-0.074	30.405	0.251

Fonte: Desenvolvido pelo autor de acordo com os dados da pesquisa

4.4 Procedimento de Previsão

Conforme afirmam Santos e Lima (2006), o modelo é adequado se considerarmos a desigualdade de Theil, onde este coeficiente deve apresentar-se próximo a zero, fato que se observa no modelo desenvolvido neste trabalho (0,007). Também de acordo com os autores, os componentes de sua decomposição Bias Proportion (Proporção de Tendenciosidade) e Variance Proportion (Proporção de Variância) devem ser próximos a zero, o que se constata

na figura 4, onde estes índices representam 0,025 e 0,029, respectivamente. Por fim, a figura também demonstra que a Covariance Proportion (Proporção de Covariância) está adequada, uma vez que está próxima a 1.




Figura 4: Modelo ARIMA (1,1,15) para ICFF (predição do ICF)

Fonte: Desenvolvido pelos autores de acordo com os dados da pesquisa

Considerando o modelo adotado, a tabela 3 apresenta a previsão *ex-ante*, ou seja, previsão de observações futuras para os doze meses subsequentes da Intenção de Consumo das Famílias (ICF), considerando as margens de erro para mais ou para menos.

Tabela 3: Previsão *ex-ante* da Intenção de Consumo das Famílias (ICFF)

Mês	ICFF	Margem Inferior	Margem Superior
Ago/2015	83,9	80	88
Set/2015	83,0	76	90
Out/2015	79,8	70	90
Nov/2015	77,8	65	90
Dez/2015	74,5	60	89
Jan/ 2016	75,1	58	92
Fev/2016	74,1	56	93
Mar/2016	71,8	52	92
Abril/2016	69,5	48	91
Mai/2016	67,7	45	91
Jun/2016	69,2	45	94
Jul/2016	70,7	45	96

Fonte: Desenvolvido pelos autores de acordo com os dados da pesquisa

A figura 5 demonstra a série original ICF em vermelho e a previsão *ex-ante* (ICFF) em azul. Considerando a predição do modelo, observa-se que o ICF deve seguir a tendência de queda durante os meses subsequentes, até atingir o nível mínimo em maio de 2016. Não foram observadas estimações para além dos doze meses subsequentes, pois as margens de erro apresentam dispersão considerável, de maneira que não é possível concluir que o índice seguirá nova tendência ascendente a partir de junho de 2016.




Figura 5: Previsão *ex-ante* Intenção de Consumo das Famílias (ICFF)
 Fonte: Desenvolvido pelos autores de acordo com os dados da pesquisa

Por fim, depende-se do modelo adotado, uma equação capaz de estimar valores para a variável dependente ICF. Retoma-se o quadro 3 para formular a equação estimadora, onde, tem-se que a estatística de Durbin-Watson (2,20) demonstra não haver problemas de autocorrelação, o R quadrado com 50% e o F-statistic bastante próximo a zero, comprovando a significância a 5%. Nesse sentido, considerando os coeficientes, os testes estatísticos e o nível de significância de cada parâmetro, tem-se a seguinte equação:

$$ICF_t = -0,96 + 0,52(ICF_{t-1}) - 0,87\varepsilon_{t-15} \quad (10)$$

T-statistics	-2,51	4,56	31,02
p-value	0,0147	0,0000	0,0000

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.964204	0.384088	-2.510376	0.0147
AR(1)	0.522842	0.114493	4.566601	0.0000
MA(15)	-0.874843	0.028203	-31.01995	0.0000
R-squared	0.500019	Mean dependent var		-0.752000
Adjusted R-squared	0.483891	S.D. dependent var		2.652614
S.E. of regression	1.905657	Akaike info criterion		4.172586
Sum squared resid	225.1549	Schwarz criterion		4.272942
Log likelihood	-132.6090	Hannan-Quinn criter.		4.212183
F-statistic	31.00238	Durbin-Watson stat		2.204597
Prob(F-statistic)	0.000000			
Inverted AR Roots	.52			
Inverted MA Roots	.99	.91-.40i	.91+.40i	.66+.74i
	.66-.74i	.31+.94i	.31-.94i	-.10+.99i
	-.10-.99i	-.50+.86i	-.50-.86i	-.80+.58i
	-.80-.58i	-.97+.21i	-.97-.21i	

Quadro 3: Estatísticas do modelo ajustado ARIMA (1,1,15)

Fonte: Desenvolvido pelos autores de acordo com os dados da pesquisa

5 Considerações finais

Com base nos resultados obtidos, concluiu-se que o modelo ARIMA (1,1,15) referente à estimação ICF a foi eficiente e apresentou projeções satisfatórias para previsão do índice. Tal alegação se deve ao fato de que a hipótese nula de que resíduos se comportam como um ruído branco não pôde ser rejeitada, assim como o modelo apresentou erro quadrado médio baixo e capacidade de previsão adequada e elevada significância dos coeficientes estimados.

Ressalta-se que a principal limitação deste trabalho foi a inexistência de estudos anteriores considerando o índice de Intenção de Consumo das Famílias, de maneira que a incompletude acaba por não permitir fazer análises mais aprofundadas. Também reconhece-se que este estudo não é conclusivo em si mesmo, razão pelo qual se sugere o uso de outros modelos para posteriores pesquisas, tais como modelos de vetores auto-regressivos (VAR) e modelos Bayesianos, a fim de analisar com mais afinco o comportamento estocástico deste processo.

REFERÊNCIAS

- BACCI, L. A.; REZENDE, M. L.; MEDEIROS, A. L. **Combinação de métodos de séries temporais na previsão da demanda de café no Brasil**. In: XXVI ENEGEP, Fortaleza, **Anais...** Rio de Janeiro: ABEPRO, 2006.
- BOX, G. E. P.; JENKINS, G. M. **Times series analysis: forecasting and control**. São Francisco: Holden-Day, 1976.
- CNC. Confederação Nacional do Comércio de Bens, Serviços e Turismo. **Pesquisa de Intenção de Consumo das Famílias (ICF)**. Rio de Janeiro, 2015. Disponível em <<http://www.cnc.org.br/central-do-conhecimento/pesquisas/economia/pesquisa-de-intencao-de-consumo-das-familias-icf-julho-de>>. Acesso em: 01/08/2015.
- FARIAS, H. P.; SÁFADI, T. Causalidade entre as principais bolsas de valores do mundo. **RAM – Revista de Administração Mackenzie**. São Paulo. v. 11, n. 2, mar/abr, 2010. pp. 96-122.
- FAVA, V. L. **Manual de econometria**. In: VASCONCELOS, M. A. S.; ALVES, D. São Paulo: Editora Atlas, 2000.
- FISHER, S. **Séries univariantes no tempo: metodologia de Box e Jenkins**. Porto Alegre: Fundação de Economia e Estatística, 1982.
- FOGLIATTO, F. S. **Previsão de demanda**. Porto Alegre: UFRGS, 2003.
- GUJARATI, D. N. **Econometria básica**. 3. ed. São Paulo: Makron Books, 2000.
- IBGE. Instituto Brasileiro de Geografia e Estatística. **Índice Nacional de Preços ao Consumidor Amplo - IPCA e Índice Nacional de Preços ao Consumidor – INPC**. Rio de Janeiro, 2015. Disponível em <http://www.ibge.gov.br/home/estatistica/indicadores/precos/inpc_ipca/defaultinpc.shtm>. Acesso em: 01/08/2015.
- IPEA. Instituto de Pesquisa Econômica Aplicada. **Gasto e consumo das famílias brasileiras contemporâneas**. MPOG/IPEA: Fernando Gaiger Silveira et al. (organizadores). Brasília: Ipea, 2007. v.2, 552 p.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. J. **Forecasting methods and applications**. 3. ed. New York: John Wiley & Sons, 1998.
- MORETTIN, P.A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Edgar Blücher, 2004.
- PINDYCK, R. S. RUBINFELD, D. L. **Econometria Modelos & Previsões**. Trad. da 4ª Edição. Rio de Janeiro: Elsevier/Campus, 2004.
- SEDDIGHI, H. R.; LAWYER, K. A.; KATOS, A. V. **Econometrics: a practical approach**. London: Routledge, 2000. 396 p.
- SANTOS, C. M. dos; LIMA, J. E. Análise de previsão da arrecadação do ICMS no Estado de Minas Gerais. **Revista de Economia e Administração**, São Paulo, v. 5, n. 4, pp. 413-423, out./dez. 2006.