Previsão de arrecadação de ICMS para o estado de Minas Gerais: uma comparação entre modelos Arima e Arfima

Filipe de Morais Cangussu Pessoa[1]
Daniel Arruda Coronel[2]
João Eustáquio de Lima[3]

Resumo

O objetivo deste trabalho foi fazer uma previsão para a série de arrecadação do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) do Estado de Minas Gerais, no período de janeiro de 1998 a agosto de 2011. Como metodologia, utilizou-se os modelos ARIMA e ARFIMA. As análises demonstraram que os modelos mais adequados para modelar a série foram os modelos ARIMA (1, 0,1) e ARFIMA (1,0. 36,1). Na avaliação dos modelos, o modelo ARIMA mostrou-se superior ao modelo ARFIMA nos critérios de Raiz Quadrada do Erro Quadrado Médio de Previsão (RQEMP), Erro Absoluto Médio de Previsão (EAMP) e Coeficiente de Desigualdade de Theiler (CDT). Por outro lado, o modelo ARFIMA mostrou-se superior pelo critério de Erro Absoluto Médio Percentual de Previsão (EAMPP). De um modo geral, os modelos se ajustaram bem aos dados e se revelaram ferramentas úteis no auxílio à tomada de decisão por parte dos gestores públicos.

Palavras-chave: ICMS; Modelo ARIMA; Modelo ARFIMA

Recebimento: 3/10/2012 • Aceite: 22/11/2012

[1] Doutorando em Economia Aplicada pela Universidade Federal de Viçosa (UFV). E-mail: filipe_morais_pessoa@yahoo.com.br

[2] Doutor em Economia Aplicada pela Universidade Federal de Viçosa. Docente da Universidade Federal de Santa Maria (UFSM). End: Prédio 74C, Térreo, Sala 4112. Bairro Camobi, km 9. Santa Maria, RS, Brasil. E-mail: danielcoronel@ufrgs.br

[3] Doutor em Economia Rural pela Michigan State University. Professor titular da Universidade Federal de Viçosa. E-mail: jelima@ufv.br

Predicting taxation on consumption of goods for the state of Minas Gerais: a comparation among Arima and Arfima models

Abstract

The aim of this work was to predict the taxations on consumption of goods of the state of Minas Gerais from January 1998 to August 2011. The methodology used was ARIMA and ARFIMA models. The analyzes showed that the most suitable models to model the series were the ARIMA (1,0,1) and ARFIMA (1,0.36,1). In evaluating of the models, the ARIMA model was superior to the ARFIMA in the criteria for Root Mean Squared Error (RMSE), Mean Absolute Prediction Error (MAPE) and Theil's Coefficient of Inequality . On the other hand, the ARFIMA model was superior in the criteria (MAPE). In general, the models fitted well to the data and have proved to be useful tools in assisting decision making by public managers.

Keywords: ICMS; ARIMA; ARFIMA Models

Introdução

Um dos principais interesses da ciência econômica é o de realizar previsões acuradas do comportamento de variáveis que desempenham papel-chave na tomada de decisão dos agentes econômicos. O governo, como um agente econômico, necessita de estimativas do comportamento futuro de uma série de variáveis.

Interesse particular está direcionado àquelas variáveis que constituem a receita tributária do governo, a partir da qual ele pode realizar os seus gastos planejados. Ademais, como destacam Marques e Uchôa (2006), legalmente, existe a exigência de se efetuar previsão de receitas pela Lei de Responsabilidade Fiscal (LRF) por parte dos poderes federal, estadual e municipal.

Existem diversos trabalhos na literatura que realizam estudos de previsão do Imposto sobre Operações relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS), os quais são justificados pelo peso desse imposto na composição da receita tributária dos governos. Dentre estes, destacam-se Santos e Costa (2008), que realizaram um estudo de previsão da arrecadação do Imposto Sobre Circulação de Mercadorias (ICMS) no Estado do Maranhão para o ano de 2008, baseando-se em uma amostra mensal que compreende o período de 2003 a 2007. Como modelo de previsão, os autores utilizaram o modelo determinístico de Alisamento Exponencial Sazonal Aditivo de Holt-Winters. Marques e Uchôa (2006) fizeram um estudo de previsão de arrecadação do ICMS para o Estado da Bahia, no período de julho de 1994 a março de 2006. Os autores utilizaram modelos autorregressivos de séries temporais e demonstraram a superioridade destes em relação aos modelos usualmente utilizados no Estado, que se baseiam em projeções de crescimento do PIB.

Liebel e Fogliatto (2005) investigaram qual o melhor modelo para previsão de arrecadação do ICMS no estado do Paraná. Os autores utilizaram modelos de regressão linear, determinísticos e autorregressivos sazonais.

Passos e Ramos (2005) também utilizaram modelos autorregressivos de séries temporais para modelar a série de ICMS do Estado do Pará, no período de 1992 a 2002. No mesmo âmbito, Arraes e Chumvichitra (1996) analisaram o desempenho de modelos autorregressivos no processo de previsão de arrecadação do ICMS com dados trimestrais de 1970 a 1995 para o Estado do Ceará. Salomão (2010) fez um estudo de previsão para a arrecadação do ICMS no

Estado do Espírito Santo mediante a utilização de modelos autorregressivos univariados e modelos multivariados com e sem a consideração de quebras estruturais pela identificação de variáveis econômicas com alto grau de correlação com a arrecadação de ICMS.

O presente estudo, seguindo a linha dos trabalhos supracitados, tem por objetivo modelar a série de ICMS do Estado de Minas Gerais visando fornecer um modelo apropriado de previsão da série. A modelagem desta série para o Estado se justifica pela importância desse imposto na composição da receita tributária, o qual, no período de 1998 a 2011, representou aproximadamente 80% de toda a receita tributária arrecadada pelo Estado, conforme a Secretaria da Fazenda de Minas Gerais (SEFAZ-MG, 2011).

Para cumprir tal objetivo, inicialmente utilizou-se como metodologia de análise modelos autorregressivos integrados de médias móveis (ARIMA) e, posteriormente, foi considerada a presença de memória longa mediante modelos autorregressivos fracionalmente integrados de médias móveis (ARFIMA) com o objetivo de comparar o desempenho de um e outro. Com isso, permite-se a flexibilização do paradigma I(0)-I(1) dado que, ao adotar a modelagem ARFIMA, pressupõe-se que o parâmetro de diferenciação fracionária possa assumir qualquer valor real e não somente valores inteiros, como na modelagem ARIMA.

O artigo está estruturado em três seções, além desta introdução. Na segunda seção, são apresentados os procedimentos metodológicos; na terceira seção, os resultados obtidos são analisados e discutidos e, por fim, são apresentadas algumas considerações finais.

Metodologia

Modelos ARIMA

Os Modelos ARIMA (do inglês *AutoRegressive Integrated Moving Average*), inicialmente formulados por Box e Jenkins (1976), também conhecidos como metodologia de Box e Jenkins, baseiam-se na ideia de que uma série temporal não estacionária pode ser modelada a partir de *d* diferenciações e da inclusão de um componente autorregressivo e um componente média móvel.

Uma série não estacionária Y_t integrada de ordem d, isto é, $Y_t \sim I(d)$, segue um modelo autorregressivo integrado de médias móveis de ordem (p, d, q) ou modelo ARIMA (p, d, q) se

$$\Delta^d Y_t = (1-L)^d Y_t = y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \cdots - \theta_p \varepsilon_{t-q}$$

$$\Delta^d Y_t = (1-L)^d Y_t = y_t = (\phi_1 L + \phi_2 L^2 + \cdots + \phi_p L^p) y_t + (1 - \theta_1 L - \theta_2 L^2 - \cdots \theta_q L^q)\varepsilon_t$$

$$(1 - \phi_1 L - \phi_2 L^2 - \cdots - \phi_p L^p) y_t = (1 - \theta_1 L - \theta_2 L^2 - \cdots \theta_q L^q)\varepsilon_t$$

$$(1 - \phi_1 L - \phi_2 L^2 - \cdots - \phi_p L^p)(1-L)^d Y_t = (1 - \theta_1 L - \theta_2 L^2 - \cdots \theta_q L^q)\varepsilon_t$$

$$\phi(L)\Delta^d Y_t = \theta(L)\varepsilon_t \qquad (1)$$

em que:

p e q são as ordens dos polinômios $\phi(L)$ e $\theta(L)$ dos componentes autorregressivos (AR) e média móvel (MA), respectivamente; e

ε_t é um processo ruído branco e d é a ordem de diferenciação da série para torná-la estacionária.

2.2 Modelos ARFIMA

Os modelos ARFIMA (p, d, q), desenvolvidos por Granger e Joyeux (1980) e Hosking (1981), foram concebidos pela flexibilização dos modelos ARIMA (p, d, q) mediante o artifício de diferenciação fracionária. Com isto, aos modelos univariados foi dada a possibilidade de modelar explicitamente tanto os componentes de alta frequência, relacionados com a memória de curto prazo, quanto os de baixa frequência, relacionados com a memória de longo prazo.

Um processo geral com diferenciação fracionária, ARFIMA (*p*, *d*, *q*), para uma série Y_t, é definido como um processo que satisfaz a seguinte equação:

$$\Phi(L)\Delta^{d^*} Y_t = \Theta(L) u_t \qquad (2)$$

em que:

p e q são as ordens dos polinômios $\Phi(L)$ e $\Theta(L)$ dos componentes autorregressivos (AR) e média móvel (MA), respectivamente, u_t é um processo ruído branco e d^* o parâmetro que captura a memória longa do processo.

Quando $-0,5<d^*<0,5$, o processo Y_t é estacionário e invertível. Para esses processos, os coeficientes da representação autorregressiva e média móvel decaem hiperbolicamente. Para $d^*= 1$, o processo segue um processo de raiz unitária. Se $0<d^*<0,5$, o processo mostra dependência positiva entre observações distantes e é estacionário com memória longa. Se $-0,5<d^*<0$, o processo apresenta dependência negativa entre observações distantes, sendo denominado de antipersistente e é estacionário com memória intermediária (HOSKING, 1981).

De acordo com Marques e Fava (2011), a análise com modelos de memória longa possui vantagens significativas no estudo da dinâmica do ajustamento no médio e longo prazo em comparação à análise tradicional de raiz unitária, pois ela consegue captar adequadamente as informações contidas nas baixas frequências das séries temporais por meio do conceito matemático da integração/diferenciação fracionária.

Medidas de avaliação de desempenho dos modelos

Para avaliar o desempenho dos modelos estimados, foram calculadas quatro medidas de avaliação, quais sejam: Raiz Quadrada do Erro Quadrado Médio de Previsão (RQEMP), Erro Absoluto Médio de Previsão (EAMP), Erro Absoluto Médio Percentual de Previsão (EAMPP) e Coeficiente de Desigualdade de Theil (CDT).

Dado Y_t e $\hat{Y}_t$ como valores observados e previstos, respectivamente, para um horizonte de previsão de T+1, T+2,..., T+h, define-se o RQEMP, EAMP, EAMPP e CDT como:

$$RQEMP = \sqrt{\sum_{t=T+1}^{T+h} \frac{(Y_t - \hat{Y}_t)^2}{h}} \qquad (3)$$

$$EAMP = \sum_{t=T+1}^{T+h} \frac{\left| Y_t - \hat{Y}_t \right|}{h} \qquad (4)$$

$$EAMPP = \sum_{t=T+1}^{T+h} \frac{\left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{h} X\,100 \qquad (5)$$

$$CDT = \frac{\sqrt{\sum_{t=T+1}^{T+h} \frac{(Y_t - \hat{Y}_t)^2}{h}}}{\sqrt{\sum_{t=T+1}^{T+h} \frac{Y_t^2}{h}} + \sqrt{\sum_{t=T+1}^{T+h} \frac{\hat{Y}_t^2}{h}}} \qquad (6)$$

Como critério de avaliação, tem-se que, quanto menor o valor dos indicadores[4], melhor é o desempenho do modelo estimado. Os dois primeiros critérios dependem da escala em que a variável de interesse está medida, já os dois últimos não. O CDT é um índice que varia entre zero e um.

Fonte de Dados

Para a realização do estudo, a série mensal de arrecadação de ICMS foi obtida junto à Secretaria de Estado de Fazenda de Minas Gerais (SEF-MG), no período de janeiro de 1998 a agosto de 2011, resultando em um total de 164 observações. Os valores da série são divulgados em Unidade Monetária Contábil (UMC), que, segundo o art.

[4] Neste estudo, os indicadores de desempenho foram calculados para valores dentro da amostra.

1º da Instrução Normativa da Comissão de Valores Mobiliários (CVM) nº 191, de 15 de Julho de 1992, trata-se de moeda de capacidade aquisitiva constante.

Os modelos ARIMA, ARFIMA e os testes de diagnóstico foram estimados no software *Stata 12.0*, já os testes de raiz unitária foram estimados no software *Eviews 7*.

Análise e discussão dos resultados

A Figura 1 apresenta a série de ICMS no período de janeiro de 1998 a agosto de 2011. Pela análise da figura, nota-se um comportamento ascendente que, a princípio, é um indicativo de tendência determinística, levando à necessidade de expurgar este efeito na modelagem da mesma. Até 2008, a série parece apresentar um padrão de volatilidade estável, no entanto, no período compreendido entre 2008 e 2010, vê-se que esse padrão de volatilidade sofre uma alteração com seu ápice no início de 2010. Tal comportamento pode estar ligado à crise norte-americana deflagrada no ano de 2008.

Figura 1: Evolução da receita tributária do estado de Minas Gerais, no período de janeiro de 1998 a agosto de 2011

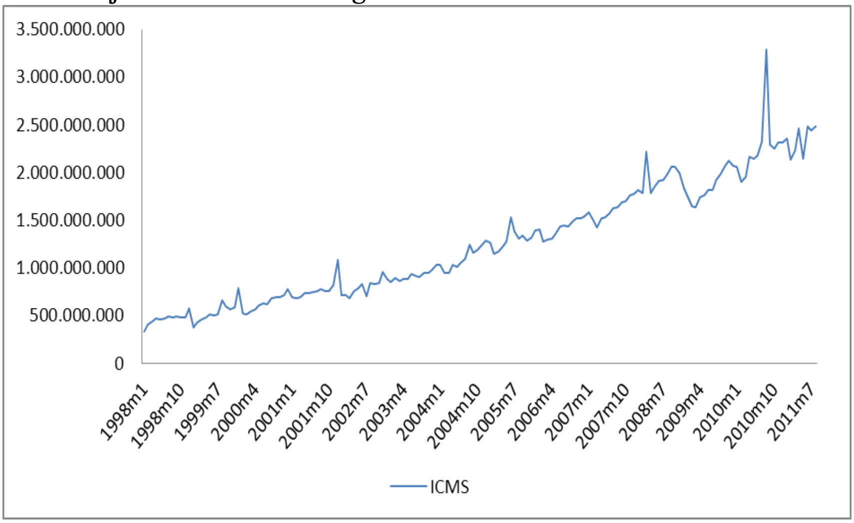

Fonte: Elaborado pelos autores com base nos dados da Secretaria de Estado da Fazenda de Minas Gerais.

Investigou-se formalmente a existência de tendência e sazonalidade determinística pelo método de Mínimos Quadrados Ordinários (MQO). O componente de tendência determinística mostrou-se relevante, já o componente de sazonalidade determinística não, dado que os coeficientes das *dummies* sazonais não foram estatisticamente significativos nem a 10% de significância.

A Tabela 1 exibe os testes de raiz unitária Augmented Dickey-Fuller (ADF, 1979)[5], Phillips e Perron (PP,1988) e Kwiatkowski et al. (KPSS,1992). Tais testes diferem quanto à especificação da hipótese nula, sendo a hipótese nula dos testes ADF e PP a presença de uma raiz unitária na série, em outras palavras, a série é integrada de ordem um - I(1), e precisa ser diferenciada uma vez para se tornar estacionária. Já o teste KPSS tem a hipótese nula de estacionariedade, o processo é I(0), não necessitando de diferenciação. O intuito de utilizar os três testes é o de executar um exercício de robustez para uma determinação mais precisa da ordem de integração da série.

Tabela 1: Testes de raiz unitária[6] para a série de ICMS de Minas Gerais, no período de janeiro de 1998 a agosto de 2011

	Estatística calculada	Valor Crítico (1%)
Teste ADF	-6.840059	-4.015341
Teste PP	-7.287696	-4.015341
Teste KPSS	0.301707	0.216000

Fonte: Resultados da pesquisa.

Os testes ADF e PP indicaram que a série de ICMS é estacionária, por outro lado, o teste KPSS indicou que a série possui uma raiz unitária. Este resultado é um primeiro indício de que a série pode ter ordem de integração intermediária entre 0 e 1, o que justifica sua modelagem mediante modelos ARFIMA.

Dado o resultado dos testes de raiz unitária para a modelagem ARIMA, optou-se por trabalhar com a série em nível. Estimaram-se diversos modelos ARIMA para valores parcimoniosos dos componentes autorregressivos e média móvel (p e q) candidatos a processo gerador da série de ICMS e escolheu-se aquele que apresentou os menores

[5] Para maiores informações, ver Morettin e Toloi (2004).

[6] Todos os testes foram realizados com a inclusão de intercepto e tendência linear na equação de teste.

valores de Critério de Informação de Akaike (CIA) e Critério de Informação Bayesiano (CIB)[7].

A Tabela 2 apresenta os modelos estimados com seus respectivos valores de critérios de informação.

Tabela 2: Estimativa dos modelos ARIMA para a série de ICMS do estado de Minas Gerais

Modelos / Parâmetros	ARIMA (1, 0,0)	ARIMA (0,0,1)	ARIMA (1,0,1)	ARIMA (2,0,0)	ARIMA (0,0,2)	ARIMA (2,0,1)	ARIMA (1,0,2)	ARIMA (2,0,2)
ϕ_1	0.540958	-	0.855694	0.433363	-	1.046679	0.890401	1.640130
	(0.0000)		(0.0000)	(0.0000)		(0.0000)	(0.0000)	(0.0000)
ϕ_2	-	-	-	0.201551	-	-0.131591	-	-0.651687
				(0.0020)		(0.4010)		(0.0910)
θ_1	-	0.401349	-0.481448	-	0.435702	-0.653943	-0.497796	-1.257571
		(0.0000)	(0.0000)		(0.0000)	(0.0010)	(0.0000)	(0.0050)
θ_2	-	-	-	-	0.238476	-	-0.069543	0.322635
					(0.0010)		(0.4580)	(0.2670)
Constante	2.33e+08	2.33e+08	2.38e+08	2.34e+08	2.33e+08	2.43e+08	2.42e+08	2.56e+08
	(0.0000)	(0.0000)	(0.0210)	(0.0040)	(0.0000)	(0.0350)	(0.031)	(0.1070)
Tendência	1.26e+07	1.26e+07	1.26e+07	1.26e+07	1.26e+07	1.26e+07	1.26e+07	1.26e+07
	(0.0000)	(0.0000)	(0.0000)	(0.0000)	(0.0000)	(0.0000)	(0.0000)	(0.0000)
Critérios de Informação								
CIA	6601.446	6620.783	6592.947	6596.695	6611.350	6594.515	6594.522	6595.837
CIB	6613.845	6633.182	6608.446	6612.195	6626.849	6613.114	6613.121	6617.536

Fonte: Resultados da pesquisa.
Nota: Valores entre parênteses representam os p-valores dos parâmetros estimados.

Com base nos resultados da Tabela 2, selecionou-se o modelo ARIMA(1,0,1), que apresentou significância estatística de todos os parâmetros a 1% de significância (exceto para a constante que foi significativa a 5% de significância), e os menores valores de CIA e CIB.

[7] As referências destes dois critérios são Akaike (1973) e Schwarz (1978), respectivamente.

Como critério de verificação, fez-se a análise da Função de Autocorrelação (FAC) dos resíduos do modelo ARIMA(1,0,1), a qual apresentou todos os valores estatisticamente iguais a zero ao nível de 1% de significância. Também realizou-se o teste Portmanteau, desenvolvido por Box e Pierce (1970) e refinado por Ljung e Box (1978), para verificar a existência de autocorrelação nos resíduos. A hipótese nula de ausência de autocorrelação nos resíduos não foi rejeitada a 1% de significância. Por fim, foi feito o teste ARCH desenvolvido por Engle (1982) para verificar se os resíduos apresentam heterocedasticidade condicional. A hipótese nula de que os resíduos não apresentam heterocedasticidade condicional (e, portanto, não apresentam efeito ARCH) não foi rejeitada a 1% de significância.

Antes de realizar as estimações dos modelos ARFIMA, faz-se necessário investigar se a série de ICMS apresenta, de fato, indícios de memória longa, o que pode ser feito pela análise do correlograma da série. A Figura 2 exibe o correlograma da série de ICMS.

Figura 2: Correlograma da série de ICMS de Minas Gerais

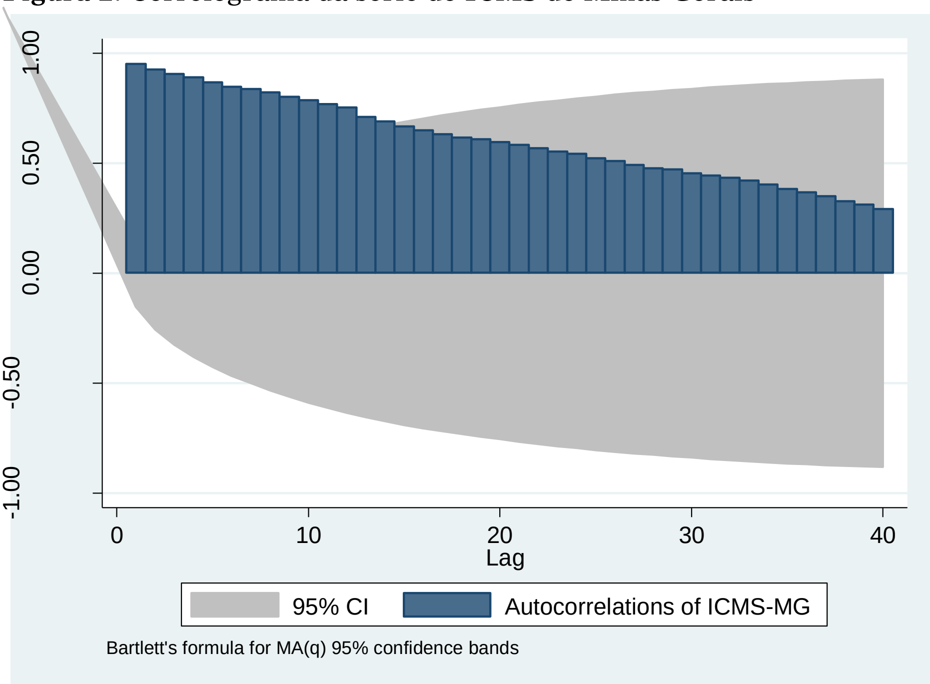

Fonte: Resultados da pesquisa.

Observa-se que o correlograma da série possui um decaimento hiperbólico, característica típica de séries que apresentam comportamento de memória longa, pois se têm correlações elevadas para valores elevados de defasagem.

Passa-se agora à estimação dos modelos ARFIMA. A Tabela 3 contém os modelos estimados com seus respectivos valores de critérios de informação[8].

Tabela 3: Estimativa dos modelos ARFIMA para a série de ICMS do estado de Minas Gerais

Modelos / Parâmetros	ARFIMA (1,d,0)	ARFIMA (0,d,1)	ARFIMA (1,d,1)	ARFIMA (2,d,0)	ARFIMA (0,d,2)	ARFIMA (2,d,1)	ARFIMA (1,d,2)	ARFIMA (2,d,2)
Φ_1	0.336947 (0.0000)		0.997237 (0.0000)	0.714065 (0.0000)		0.978518 (0.0000)	0.997162 (0.0000)	-
Φ_2				0.283389 (0.0010)		0.018612 (0.9150)		-
Θ_1		0.227675 (0.0000)	-0.886521 (0.0000)		0.212921 (0.0090)	-0.891216 (0.0000)	-0.914658 (0.0000)	-
Θ_2					0.184170 (0.0040)		0.019721 (0.8510)	-
Constante	1.30e+09 (0.2400)	1.30e+09 (0.3030)	1.51e+09 (0.5260)	1.35e+09 (0.0280)	1.30e+09 (0.2820)	1.52e+09 (0.5510)	1.52e+09 (0.5550)	-
Parâmetro d*	0.493401 (0.0000)	0.496429 (0.0000)	0.355118 (0.0000)	-0.147176 (0.0130)	0.495223 (0.0000)	0.370405 (0.0000)	0.373982 (0.0000)	-
Critérios de Informação								
CIA	6655.049	6661.719	6601.649	6612.815	6654.15	6601.628	6601.627	-
CIB	6658.149	6664.819	6604.749	6615.915	6657.25	6604.728	6604.726	-

Fonte: Resultados da pesquisa.
Nota: Valores entre parênteses representam os p-valores dos parâmetros estimados.

[8] O modelo ARFIMA(2,d,2) não foi possível de ser estimado pelo fato de o algoritmo de otimização utilizado pelo software *Stata 12.0* informar que, para este caso, o valor de d estimado estava fora do intervalo de estimação.

Ao observar as estimativas dos modelos na Tabela 3, constata-se que o modelo ARFIMA (1,0. 36,1) foi o que apresentou o menor valor para os critérios CIA e CIB, juntamente com a significância estatística a 1% de significância de todos os parâmetros, exceto a constate, sendo, assim, o modelo selecionado.[9]

Para verificar a adequação do modelo, novamente fizeram-se os testes Portmanteau de autocorrelação serial nos resíduos e ARCH, de heterocedasticidade condicional nos resíduos. O resultado permaneceu qualitativamente inalterado em relação ao modelo ARIMA, ou seja, não se rejeitam ambas as hipóteses nulas a 1% de significância, desta forma, o modelo apresenta ausência de autocorrelação serial e ausência de heterocedasticidade condicional nos resíduos. A análise da FAC dos resíduos apresentou todos os valores estatisticamente iguais a zero ao nível de 1% de significância.

Pelo valor do parâmetro de diferenciação fracionária estimado (d^{*}=0.36), conclui-se que a série de ICMS para o estado de Minas Gerais, no período de janeiro de 1998 a agosto de 2011, é estacionária com memória longa, confirmando a análise previamente feita através do correlograma.

Este resultado revela que, se a análise de estacionariedade tivesse sido feita pelo teste KPSS, chegar-se-ia à conclusão de que a série possui uma raiz unitária e necessitaria ser diferenciada uma vez para se tornar estacionária. Esta transformação introduziria um viés de sobrediferenciação na série.

A Tabela 4 exibe o desempenho dos dois modelos selecionados (ARIMA(1,0,1) e ARFIMA(1,0.36,1)), avaliados dentro da amostra (ou seja, no período de janeiro de 1998 a agosto de 2011), segundo os três critérios já mencionados na seção metodológica.

[9]Os modelos ARFIMA(2,0.37,1) e ARFIMA(1,0.37,2) apresentaram valores menores para os critérios CIA e CIB, contudo, os termos AR(2), no primeiro modelo e MA(2), no segundo modelo, não foram estatisticamente significativos a 1% de significância, o que levou à opção pelo modelo ARFIMA(1,0.36,1).

Tabela 4 – Avaliação do desempenho dos modelos ARIMA(1,0,1) e ARFIMA(1,0.36,1) dentro da amostra

Critérios de Desempenho	Modelos	
	ARIMA(1,0,1)	ARFIMA(1,0.36,1)
RQEMP	125995275.00	130010398.88
EAMP	71121694.83	73842444.07
EAMPP	6.13	6.03
CDT	0.044989	0.046806

Fonte: Resultados da pesquisa.

Conforme Tabela 4, o modelo ARIMA(1,0,1) apresentou melhor desempenho nos critérios RQEMP, EAMP e CDT, já o modelo ARFIMA apresentou melhor desempenho no critério EAMPP. De certa forma, os resultados de ambos os modelos se mostraram próximos, o que é corroborado pela Figura 3, onde pode ser vista a série original de ICMS e as séries previstas pelos modelos ARIMA e ARFIMA selecionados.

Figura 3: Comparativo entre as previsões dos modelos ARIMA(1,0,1) e ARFIMA(1,0.36,1)

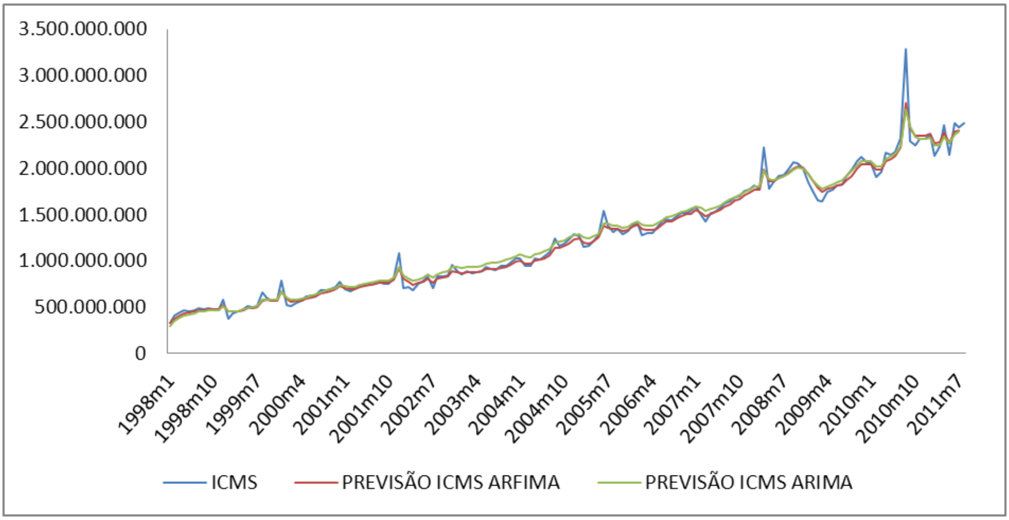

Fonte: Resultados da pesquisa

Conclusão

Uma adequada previsão da receita tributária é ferramenta fundamental para auxiliar a tomada de decisão por parte dos gestores públicos, os quais dependem das receitas dos impostos para manter e dimensionar o funcionamento da máquina pública enquanto agente promotor de bem-estar social.

Com a Lei Complementar 101/2000, conhecida como Lei de Responsabilidade Fiscal (LRF), a necessidade de previsão passou a ser regulamentada, e, em decorrência disso, as exigências sobre os analistas fazendários passaram a ser objetivamente determinadas. Conforme prescreve o art.11 da referida lei: "Constituem requisitos essenciais da responsabilidade na gestão fiscal a instituição, *previsão* [10]e efetiva arrecadação de todos os tributos da competência constitucional do ente da Federação"

Diante do exposto, o presente estudo procurou modelar a série de ICMS para o estado de MG, respaldado pelo peso deste imposto na composição da receita tributária estadual. Visando cumprir este objetivo, utilizaram-se os modelos ARIMA e ARFIMA no intuito de flexibilizar os valores assumidos pelo parâmetro de integração para captar características de memória longa e possibilitar a comparação de um e outro modelo.

Os critérios de informação CIA e CIB indicaram os modelos ARIMA(1,0,1) e ARFIMA(1,0.36,1) como os de melhor ajuste. Na comparação de ambos, o modelo ARIMA superou o modelo ARFIMA nos critérios de desempenho RQEMP, EAMP e CDT, enquanto o modelo ARFIMA foi melhor no critério EAMPP. De maneira geral, os modelos estimados tiveram um bom ajuste aos dados e se mostraram ferramentas úteis para prever valores futuros da série de ICMS, contudo sugere-se, para estudos futuros, a estimação para a série de arrecadação do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) dos demais estados brasileiros com o objetivo de verificar se estes modelos se ajustam bem aos dados dos demais estados da federação.

Referências

AKAIKE H. Information theory and an extension of the maximum likelihood principle. In: PETROV BN, CSAKI F (Edit.). **Second**

[10]Grifo dos autores

International Symposium on Information Theory. Budapest: Akademia Kiado, 1973. p. 267–281.

ARRAES, R. A.; CHUMVICHITRA, P. **Modelos autoregressivos e poder de previsão**: uma Aplicação com o ICMS. Programa de Pós-Graduação em Economia, Universidade Federal do Ceará, (Texto para discussão, 152, b).

BOX, G. E. P. ; JENKINS, G. M. **Time series analysis**: forecasting and control. Revised Edition. San Francisco: Holden-Day, 1976.

BOX, G.E.P.; PIERCE, D.A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models, **Journal of the American Statistical Association**, v.65, n.32, p. 1509-1526, 1970.

BRASIL. Congresso Nacional. L**ei Complementar nº 101, de 04 de Maio de 2000**. Estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências. Disponível em:

<http://www.planalto.gov.br/ccivil_03/leis/LCP/Lcp101.htm>. Acesso em: 12 de nov., 2011.

BRASIL. Ministério da Fazenda. **Comissão de Valores Mobiliários. Instrução Normativa nº 191, de 15 de julho de 1992**. Institui a Unidade Monetária Contábil, dispõe sobre os procedimentos para elaboração e divulgação das demonstrações contábeis em moeda de capacidade aquisitiva constante, para o pleno atendimento aos Princípios Fundamentais de Contabilidade, e dá outras providências. Disponível em:

http://www.cvm.gov.br/asp/cvmwww/atos/exiato.asp?Tipo=I&File=/inst/inst191.htm> Acesso em: 07 de nov., 2011.

DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root. **Journal of the American Statistical Association**, v.74 n.366 p 427-431, 1979.

ENGLE, R. Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation, **Econometrica**, v.50, n.4 p.987-1008, 1982.

GRANGER, C.W.J.; JOYEUX, R. An introduction to long memory time series models and fractional differencing, **Journal of Time Series Analysis,** v.1, n.1, p.5–39, 1980.

HOSKING, J.R.M. Fractional differencing, **Biometrika**. v.68, n.1, p.165–176, 1981.

KWIATKOWSKI, D et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-1992.

LIEBEL, M. J.; FOGLIATTO, F. S.. **Método para previsão de receita tributária.** In: XXV Encontro Nacional de Engenharia de Produção, 2005, Porto Alegre. Anais do XXV ENEGEP. Porto Alegre: Editora da FEENG, v. 1. p. 1-8, 2005.

LJUNG, G.M.; BOX, G.E.P. On measure of lack of fit in time series models. **Biometrika**, v.65, n.2 p.297-303,1978.

MARQUES, G. de O. L. C; FAVA, V. L. Persistência e memória longa sazonal na série de desemprego da região metropolitana de São Paulo. **Economia Aplicada** v. 15, n.2 p. 177-198, 2011.

MARQUES, C. A. G. ; UCHÔA, C. F. A. Estimação e previsão do ICMS na Bahia. **Revista Desenbahia**, v. 3, p. 195-211, 2006.

MINAS GERAIS. Secretaria de Estado de Fazenda. Subsecretaria da Receita Estadual. **Superintendência de Arrecadação e Informações Fiscais**. Disponível em: < http://www.fazenda.mg.gov.br/governo/receita_estado/evolucaoreceita/>. Acesso em 07 de nov., 2011.

MORETTIN, P.A.; TOLOI, C.M.C. **Modelos para previsão de séries temporais.** São Paulo: Edgard Blücher, 2004.

PASSOS, J. J. ; RAMOS, E. M. L. S.. **Modelagem estatística para previsão de arrecadação de ICMS do Estado do Pará.** In: XI Reunion de Trabajo em Procesamiento de la Informacion y Control, 2005, Rio Cuarto. XI Reunion de Trabajo em Procesamiento de la Informacion y Control. Rio Cuarto : Universidad Nacional de Rio Cuarto, 2005. v. 01. p. 248-253.

PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression, **Biometrika**, v. 75, n. 2, 1988.

SALOMÃO, M.F.. **A arrecadação de ICMS no Estado do Espírito Santo: análise da evolução recente e modelos econométricos para previsão de receita.** In: I Encontro de Economia do Espírito Santo, 2010, Vitória, ES. Anais do I Encontro de Economia do Espírito Santo, 2010.

SANTOS, A.V. e COSTA, J.H.F. Análise de modelos de séries temporais para a previsão mensal do ICMS do Estado do Maranhão para Ano de 2008. **Cadernos IMESC** – Instituto Maranhense de Estudos Socioeconômicos e Cartográficos, 2008.

SHWARTZ, G. Estimating the dimension of a model, **Ann. Stat**., v. 6, n.2, p. 461–464, 1978.