



UNIVERSIDADE FEDERAL DO CEARÁ
PÓS-GRADUAÇÃO EM ECONOMIA - CAEN
MESTRADO PROFISSIONAL EM ECONOMIA DO SETOR PÚBLICO – MESP

SARAH VIRGINIA PAIVA FONTENELE

Arrecadação Tributária: Modelos de Previsão para o Estado do Ceará

FORTALEZA - CEARÁ

2017

SARAH VIRGINIA PAIVA FONTENELE

ARRECADAÇÃO TRIBUTÁRIA: MODELOS DE PREVISÃO PARA O ESTADO
DO CEARÁ

Dissertação submetida à Coordenação do
Curso de Mestrado em Economia, da
Universidade Federal do Ceará, como
requisito parcial para a obtenção do grau
de Mestre em Economia.

Orientador: Prof. Dr. Emerson Luís
Lemos Marinho.

FORTALEZA - CEARÁ

2017

SARAH VIRGININA PAIVA FONTENELE

ARRECADAÇÃO TRIBUTÁRIA: MODELOS DE PREVISÃO PARA O ESTADO
DO CEARÁ

Dissertação de Mestrado apresentada ao Centro de Aperfeiçoamento de Economistas do Nordeste - CAEN, da Universidade Federal do Ceará, como requisito parcial para obtenção do título de Mestre em Economia.

Aprovada em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Emerson Luís Lemos Marinho (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Ricardo Antônio de Castro Pereira
Universidade Federal do Ceará (UFC)

Prof. Dr. Márcio Veras Corrêa
Universidade Federal do Ceará (UFC)

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- F763a Fontenele, Sarah Virginia Paiva.
Arrecadação Tributária: Modelos de Previsão para o Estado do Ceará / Sarah Virginia Paiva Fontenele.
– 2017.
37 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Faculdade de Economia, Administração,
Atuária e Contabilidade, Mestrado Profissional em Economia do Setor Público, Fortaleza, 2017.
Orientação: Prof. Dr. Emerson Luís Lemos Marinho.

1. Arrecadação Tributária. 2. Box e Jenkins. 3. Séries Temporais. 4. Previsão. I. Título.

CDD 330

AGRADECIMENTOS

Em primeiro lugar a Deus por ter oportunidade de estudar.

Aos meus pais, Hélio e Cecília, que sempre me incentivaram a perseguir os meus sonhos, a estudar e nunca desistir perante os obstáculos.

À minha avó Cecy pelo exemplo de resiliência diante das adversidades.

Aos meus irmãos, Marcelo, Lia, Cristiano, Giselle e Ana Cláudia, que são meus exemplos e estão sempre ao meu lado me encorajando em meus projetos.

A Sefaz-CE, instituição onde trabalho e que muito apóia seus servidores a se capacitarem.

À Auditece por ter organizado esta turma específica para os servidores da Sefaz-CE.

Ao Prof. Emerson Marinho por ter aceitado o convite para ser meu orientador.

Ao monitor Cristiano da Silva por ter me auxiliado com as inúmeras dúvidas que tive ao longo desta jornada.

Às colegas Francisca Fabiana e Selma por termos nos unido e formado uma equipe, fazendo com que os desafios ao longo do curso fossem mais facilmente transpostos.

Aos funcionários do CAEN, Márcia e Cléber, pelo suporte e disponibilidade em ajudar.

RESUMO

A presente dissertação utiliza a metodologia de *Box e Jenkins* para realizar previsões mensais da arrecadação tributária do ICMS e IPVA para o Estado do Ceará. Modelando a presença de não estacionariedade, defasagens no componente autorregressivo e de média móvel, assim como sazonalidade, os critérios de informação indicaram dois modelos de previsão *SARIMA* para cada tributo. A análise dos resíduos indicou a não existência de autocorrelação serial em nenhum dos modelos estimados, confirmando a hipótese de que os mesmos se comportam como processos de ruídos brancos. As previsões derivadas para o período de janeiro à dezembro de 2016 indicaram uma boa acurácia das previsões de arrecadação do ICMS e um comportamento preditivo irregular com relação à arrecadação do IPVA.

Palavras-Chave: Arrecadação Tributária, *Box e Jenkins*, Séries Temporais, Previsão.

ABSTRACT

This work uses the methodology of Box and Jenkins to perform monthly forecasts of tax collection of ICMS and IPVA for Ceará State. Modeling the presence of non-stationarity, lags in the autoregressive and moving average components, as well as seasonality, the information criteria indicated two *SARIMA* forecast models for each tribute. The residual analysis indicated the absence of serial autocorrelation in any of the estimated models, confirming a hypothesis that they behave as white noise processes. The exercise of forecasting derived for the period from January to December of 2016 indicated a good accuracy of forecasts to ICMS and an irregular predictive behavior regarding IPVA.

Keywords: Tax Collection, Box and Jenkins, Time Series, Forecasting.

LISTA DE FIGURAS

Figura 1: Comportamento mensal das séries do ICMS e IPVA.....	17
Figura 2: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) do ICMS.....	25
Figura 3: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) do IPVA.....	26
Figura 4: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) dos resíduos – ICMS.....	28
Figura 5: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) dos resíduos - IPVA.	30

LISTA DE TABELAS

Tabela 1: Teste de Raiz Unitária, Dickey-Fuller Aumentado (ADF)	25
Tabela 2: Modelos Estimados para o ICMS	27
Tabela 3: Testes sobre os resíduos estimados	28
Tabela 4: Modelos Estimados para o IPVA	29
Tabela 5: Testes sobre os resíduos estimados - IPVA	30
Tabela 6: Previsão de arrecadação mensal do ICMS para fora da amostra	31
Tabela 7: Medidas de eficiência de Previsão - ICMS	32
Tabela 8: Previsão de arrecadação mensal do IPVA para fora da amostra	33
Tabela 9: Medidas de eficiência de Previsão - IPVA.....	33

SUMÁRIO

1	INTRODUÇÃO.....	11
2	REVISÃO DE LITERATURA	13
2.1	TRIBUTOS.....	13
2.2	PREVISÃO.....	14
3	METODOLOGIA.....	16
3.1	BASE DE DADOS	16
3.2	Modelos de Previsão.....	17
3.2.1	<i>Modelos ARIMA.....</i>	<i>18</i>
3.2.2	<i>Modelos SARIMA.....</i>	<i>19</i>
3.2.3	<i>Identificação</i>	<i>20</i>
3.2.4	<i>Estimação e Checagem do Modelo.....</i>	<i>20</i>
3.2.5	<i>Previsão</i>	<i>21</i>
4	RESULTADOS	23
4.1	TESTE DE RAIZ UNITÁRIA.....	23
4.2	IDENTIFICAÇÃO DOS MODELOS AJUSTADOS	25
4.3	ESTIMAÇÃO E CHECAGEM DOS RESÍDUOS	27
4.3.1	<i>ICMS.....</i>	<i>27</i>
4.3.2	<i>IPVA.....</i>	<i>29</i>
4.4	PREVISÃO.....	30
4.4.1	<i>Análise de Previsão - ICMS.....</i>	<i>31</i>
4.4.2	<i>Análise de Previsão - IPVA</i>	<i>32</i>
5	CONSIDERAÇÕES FINAIS	34
	REFERÊNCIAS.....	36

1 INTRODUÇÃO

A receita tributária representa a principal entrada de fluxo de caixa para os estados do Brasil. A partir dessa arrecadação de recursos se torna possível a adoção de uma série políticas públicas de cunho econômico e social, bem como a viabilização de repasse de verbas aos municípios.

Aliado à necessidade de garantir o bem-estar social, dado a restrição orçamentária, o crescente movimento em direção a profissionalização da gestão financeira pública, como a Lei de Responsabilidade Fiscal, vem obrigando os administradores públicos a estimarem com boa antecedência os resultados futuros das variáveis que constituem a arrecadação tributária administrada pelo governo, de modo a garantir um planejamento mais eficiente dos gastos públicos de longo prazo (KAVANAGH; IGLEHART, 2012).

Do ponto de vista do Estado do Ceará, segundo os dados disponibilizados pela Secretaria da Fazenda (SEFAZ)¹, a receita tributária efetivamente arrecadada em 2015 atingiu o valor de R\$ 11,315 bilhões. Na composição dessa arrecadação, o ICMS² apresentou a parcela mais expressiva, representando 86,14% da arrecadação. Já o IPVA³ representou 5,71% da arrecadação. Dessa forma, os dois impostos representam na sua totalidade 91,85% da estrutura tributária do Estado, sendo estes tributos foco de análise na presente dissertação⁴.

Dado sua importância na composição da receita tributária estadual, há na literatura econômica regional uma série de estudos que buscaram identificar modelos de previsão para a arrecadação do ICMS no Ceará através de metodologias de séries temporais univariadas (CASTELAR; FERREIRA; LINHARES, 1996; SILVESTRE, 2014) e metodologias multivariadas (SANTANA, 2009), porém, nenhum trata da análise do tributo IPVA. Nessa linha, a presente dissertação tem por objeto de pesquisa a investigação, a partir de ferramentas econométricas, dos melhores modelos de previsão

¹ Dados extraídos do Balanço Geral do Estado – Exercício 2015. Disponível em: http://www.sefaz.ce.gov.br/Content/aplicacao/internet/financas_publicas/balanco_geral/bge_2015.pdf

² Imposto sobre Operações relativas à Circulação de Mercadorias e Prestação de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação.

³ Imposto sobre a Propriedade de Veículos Automotores.

⁴ Devido à falta de informações desagregadas, o imposto ITCMD – Transmissão Causa Mortis e Doação – foi excluído da análise.

para o ICMS e IPVA no Estado do Ceará, avaliando quais modelagens estruturais se alinham melhor para cada tipo de tributo analisado.

Para cumprir esse objetivo, a estratégia econométrica seguirá a metodologia de Box-Jenkins (ARIMA), buscando prever os valores futuros para a arrecadação tributária do Estado do Ceará a partir das informações passadas dos próprios tributos. Os diversos candidatos a melhor modelo de previsão de cada tributo serão ajustados por meio de critérios de previsão para dentro da amostra e serão validados via previsão para fora da amostra.

No intuito de realizar essas previsões para os dois principais impostos estaduais do Ceará, a pesquisa utilizará informações mensais sobre a arrecadação do ICMS e IPVA, para o período de janeiro de 1998 até dezembro de 2016. Os exercícios de previsão serão realizados com um horizonte de até doze meses à frente, integralizando, portanto, o intervalo de janeiro até dezembro de 2016.

A dissertação será particionado em cinco seções. Além dessa introdução, no capítulo subsequente, será abordada uma breve análise sobre os tributos a serem analisados e a revisão da literatura econômica. No terceiro capítulo, será apresentada a base de dados necessária para a implantação da pesquisa, bem como os principais aspectos metodológicos da dissertação. Em seguida serão expostos os modelos de previsão estimados e seus respectivos resultados. Por fim, no quinto capítulo serão explicitadas as considerações finais.

2 REVISÃO DE LITERATURA

O objetivo dessa seção é realizar uma síntese dos principais aspectos relacionados ao sistema de tributação do ICMS e IPVA. Em seguida se realizará um breve resumo sobre a literatura relacionada à proposição de modelos de previsão para a arrecadação tributária a nível regional.

2.1 TRIBUTOS

O ICMS é o imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação, de competência dos Estados e do Distrito Federal. Sua regulamentação constitucional está prevista na Lei Complementar 87/1996, alterada posteriormente pelas Leis Complementares 92/97, 99/99 e 102/2000 (BRASIL, 1996).

A Lei nº 12.670 - DOE de 27 de dezembro de 1996 - dispõe acerca do imposto no estado do Ceará, abordando as hipóteses de incidência do imposto, fato gerador, alíquotas, entre outros. A alíquota do ICMS nas operações internas é de 25% para as bebidas alcoólicas, armas, munições, fogos de artifício, fumo, cigarros e demais artigos de tabacaria, jóias, aviões ultraleves, asa-delta, energia elétrica, gasolina, querosene de aviação, óleo diesel e álcool anidro hidratado para fins combustíveis; de 17% para as demais mercadorias ou bens; e 12% para as operações realizadas com leite tipo longa vida. (BRASIL, 1996).

Por meio da Lei nº 16.177/2016 – DOE de 27 de dezembro de 2016 –, alterou-se a Lei nº 12.670/96, que trata do ICMS, majorando, de 17% para 18%, a alíquota interna do ICMS, regra geral, aplicável aos produtos para os quais não haja previsão de alíquota específica e para os serviços de transporte intermunicipal.

O IPVA é o imposto sobre a propriedade de veículos automotores de qualquer espécie. O tributo é pago anualmente e os contribuintes deste são os proprietários de veículos. A receita do IPVA é dividida de forma igualitária entre o estado e o município onde o veículo é licenciado. A base de cálculo do imposto é o valor corrente do veículo automotor, levando-se em conta os preços praticados no mercado e os divulgado em publicações especializadas.

As alíquotas do imposto variam de 1% para ônibus, micro-ônibus, caminhões e cavalos mecânicos; 2% para motocicletas e similares; e 2,5% para automóveis, caminhonetes, embarcações recreativas ou esportivas (BRASIL, 1992)

2.2 PREVISÃO

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 o objetivo de investigar o comportamento temporal da arrecadação de ICMS cearense, Castelar, Ferreira e Linhares (1996) utilizaram um conjunto de procedimentos metodológicos – Alisamento Exponencial, modelo ARIMA e Função Transferência – para a construção de previsões mensais. Os resultados indicaram erros de previsão oscilando entre 2.7% e 9.6%, em valores absolutos, denotando uma boa capacidade preditiva do modelo ajustado.

Santana (2009) realiza previsões para a arrecadação mensal do ICMS cearense por meio de técnicas econométricas, no intuito de obter um modelo mais eficiente possível. Tal eficiência é definida pela sua capacidade de gerar previsões de arrecadação do ICMS com a menor margem de erro possível. Para atingir ao objetivo, o autor utilizou Modelos de Correções de Erros (MCE), no qual o vetor cointegrante foi estimado por DOLS (Dynamic Ordinary Least Squares).

O autor utiliza informações mensais do volume de combustível derivado do petróleo comercializado pelas distribuidoras, e do consumo de energia elétrica comercial e industrial, para o Estado do Ceará, no período de janeiro de 2000 até julho de 2007. As previsões geradas confirmam a capacidade preditiva do MCE, devido à pequena margem de erro. Além desse resultado, o modelo MCE, empregado por Santana (2009), demonstra-se mais acurado do que o método utilizado pela Secretaria da Fazenda do Estado do Ceará na previsão de arrecadação mensal de ICMS.

Com o objetivo de realizar projeções de valores futuros da arrecadação de ICMS para o Estado de Minas Gerais, Pessoa, Coronel e Lima (2013) realizam uma comparação entre os modelos ARIMA e ARFIMA, no período de janeiro de 1998 a agosto de 2011. Os resultados indicam que o modelo ARIMA mostrou-se superior ao modelo ARFIMA segundo os critérios de Raiz Quadrada do Erro Quadrado Médio de Previsão

(RQEMP), Erro Absoluto Médio de Previsão (EAMP) e Coeficiente de Desigualdade de Theil (*TIC*). Por outro lado, o modelo ARFIMA apresenta melhor capacidade preditiva segundo o critério de Erro Absoluto Médio Percentual de Previsão (EAMPP). De um modo geral, os modelos se ajustaram bem aos dados, revelando-se ferramentas úteis para prever valores futuros da série do ICMS e no auxílio à tomada de decisão por parte dos gestores públicos.

Em uma linha mais próxima à abordada na presente dissertação, Camargos (2008) desenvolve modelos do tipo ARIMA, segundo a metodologia de Box & Jenkins, para a previsão da arrecadação tributária do Estado de São Paulo, dividida pelos tributos ICMS, IPVA, ITCMD/ITBI e Taxas. Os dados foram levantados a partir de pesquisas realizadas junto à Secretaria da Fazenda do Estado de São Paulo, referente ao período mensal de 1997:1 a 2007:12.

Para cada tributo foram desenvolvidas regressões considerando a diferenciação da variável dependente, a inclusão de variáveis *dummies* mensais e a inclusão de *lags* de sazonalidade, tendo como base as séries históricas dos respectivos tributos. Com isso, chega-se a um modelo para cada imposto: ICMS, IPVA, ITBI/ITCMD e Taxas. Os resultados evidenciam diferentes modelos de previsão para cada imposto específico, de modo que o modelo final para ICMS foi um modelo ARMA (12,12), com *dummies* sazonais para janeiro a dezembro; enquanto que o modelo final para o IPVA foi o modelo SARIMA(0,1,1)(12,1,12), com *dummies* sazonais para janeiro, fevereiro, abril, outubro e dezembro.

3 METODOLOGIA

3.1 BASE DE DADOS

As séries históricas a serem exploradas na dissertação serão extraídas do sítio eletrônico da Secretaria da Fazenda (SEFAZ/CE). As informações financeiras sobre a arrecadação tributária do estado do Ceará serão analisadas através de dois tipos de impostos:

- ICMS;
- IPVA;


A SEFAZ disponibiliza informações sobre os grupos de impostos em termos nominais, com frequência mensal, essas séries serão deflacionadas através do Índice de Preços ao Consumidor Amplo (IPCA) e analisadas em termos reais. As duas variáveis de receita tributária serão utilizadas em termos mensais, contemplando o intervalo de janeiro de 1998 até dezembro de 2016, sendo a amostra composta por 228 observações de cada série.

Cabe destacar que para o processo de identificação e estimação do modelo a ser ajustado será utilizado o sub-intervalo temporal dentre janeiro de 1998 até dezembro de 2015. Já as informações referentes ao período de 2016 serão deixadas fora da amostra, para que as previsões realizadas para a arrecadação tributária do ICMS e IPVA sejam comparadas com os valores observados, permitindo, assim, a inferência sobre a precisão do modelo ajustado.

No intuito de suavizar as séries, será tomado o logaritmo neperiano de seus valores. Destaca-se que ao final do processo de modelagem, será tomado o exponencial (anti-log) dos valores estimados para fora amostra, a fim de comparar os valores previstos com os valores observados para a época subjacente.

A figura 1 reporta o comportamento temporal das séries do ICMS e IPVA, respectivamente, para o intervalo temporal de análise. A série de arrecadação tributária do ICMS apresenta uma tendência de crescimento em sua arrecadação ao longo do período amostral analisado, existindo também um padrão oscilatório dentro de cada ano, sugerindo a presença de sazonalidade na variável. Quanto a série do IPVA, observa-se que o imposto apresenta forte sazonalidade no início do ano e uma tendência visual de crescimento no volume arrecadado ao longo do tempo.

Figura 1: Comportamento mensal das séries do ICMS e IPVA



Fonte: Elaborado pela autora.

Logo, o cenário imposto em ambos casos indica a necessidade de verificar a estacionariedade das séries e de modelar o comportamento sazonal das mesmas.

3.2 Modelos de Previsão

Dentro da literatura econômica existem diversas técnicas de previsão de cunho tanto qualitativo quanto quantitativo. Via de regra, as abordagens qualitativas ou métodos de previsão subjetivos são formados pela opinião de agentes especializados, a partir das informações disponíveis sobre os fenômenos em questão. Dentre as principais restrições desse tipo de abordagem, uma que se destaca é a ausência de um mecanismo de previsão que explicitamente formalmente a forma pela qual as informações disponíveis são incorporadas no modelo de previsão (ABRAHAM; LETOLDER, 2009). Esta restrição impossibilita a extensão do modelo para períodos posteriores à previsão modelada, haja vista que o modelo adotado só é válido para a previsão pontual realizada.

Por outro lado, processos de previsão que são baseados em modelos matemáticos ou estatísticos são nomeados como modelos quantitativos. Tais abordagens podem ser divididas entre técnicas multivariadas e univariadas.

Os modelos multivariados constroem estimativas de previsão para uma dada variável através do auxílio de uma regressão representando as relações entre um conjunto de variáveis relacionadas. Neste quadro destacam-se os modelos de previsão VAR e ECM.

Já os modelos univariados utilizam informações passadas da variável de interesse para construir uma previsão de resultados futuros para a mesma. Nesta linha existem diversas abordagens matemáticas tais como alisamento exponencial, decomposições univariadas, médias móveis e Box-Jenkins.

A abordagem de Box-Jenkins destaca-se devido a uma série de vantagens, tais como:

- i) Não utilização de variáveis explicativas exógenas, evitando a propagação dos erros dessas variáveis no modelo.
- ii) O modelo segue o princípio da parcimônia, evitando modelos com alto grau de complexidade.
- iii) Suas estimativas possuem boas propriedades preditivas de curto e médio prazos.

3.2.1 Modelos ARIMA

O processo de previsão das variáveis selecionadas será realizado através do modelo $ARIMA(p, d, q)$, desenvolvido por Box e Jenkins (1976). Esta metodologia tem sido amplamente utilizada para fins de previsão na literatura econômica devido as suas propriedades desejáveis, sendo possível utiliza-la para a previsão de séries temporais tanto estacionárias, quanto não-estacionárias.

Algebricamente, uma série de tempo $\{Y_t\}$ – representando as séries de arrecadação do ICMS e IPVA para o Estado do Ceará – pode ser descrito como um processo $ARIMA(p, d, q)$ se:

$$(1 - L)^d Y_t = y_t \quad (1)$$

Onde L denota o operador de defasagem e d a ordem de integração, que torna y_t uma variável estocástica estacionária em média e variância, sendo representada por um processo $ARMA(p, q)$ da forma:

$$y_t = \phi_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j}, \quad i = 1, \dots, p; \quad j = 0, \dots, q \text{ e } \phi_0 = 1 \quad (2)$$

Onde p e q representam as ordens do processo autoregressivo e do processo de média móvel, respectivamente. Já os vetores $\phi = (\phi_1, \dots, \phi_p)^T$ e $\theta = (\theta_1, \dots, \theta_q)^T$ denotam os coeficientes estimados da parte autoregressiva e de média móvel,

respectivamente, representando os pesos relativos dos valores passados e dos choques aleatórios na estimativa de y_t . Por final, $\{\varepsilon_{t-j}, j = 1, \dots, q\}$ representa uma sequência de erros aleatórios *i. i. d* $N(0, \sigma^2)$.

3.2.2 Modelos SARIMA

Uma extensão natural dos modelos *ARIMA* na presença de autocorrelação sazonal consiste na adição de componentes autoregressivos sazonais e componentes de médias móveis sazonais, construindo o modelo *SARIMA* $(p, d, q)(P, D, Q)_{12}$, onde P representa o número de componentes autoregressivos sazonais, D a ordem de integração sazonal, e Q o número de defasagens de médias móveis sazonais.

Reescrevendo o modelo *ARIMA*, equação (2), a partir da introdução do operador defasagem L , têm-se:

$$\phi_p(L)\Delta^d Y_t = \theta_q(L)\varepsilon_t \quad (3)$$

Em que o operador autorregressivo $\phi_p(L)$ é definido por $\phi_p(L) = (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)$, o operador de média móvel é tido como $\theta_q(L) = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q)$ e $\Delta^d Y_t = (1 - L)^d Y_t$, sendo d é a ordem de integração do processo gerador dos dados da série Y_t .

Os parâmetros que capturam os componentes periódicos do sistema, períodos de sazonalidade latente, são adicionados de forma multiplicativa à equação (3), de forma a definir o modelo *SARIMA* $(p, d, q)(P, D, Q)_S$, o qual pode ser representado algebricamente como:

$$\phi_p(L)\Phi_P(L^S)\Delta^d \Delta^D Y_t = \theta_q(L)\Theta_Q(L^S)\varepsilon_t \quad (4)$$

Onde $\Delta^D Y_t = (1 - L)^S Y_t$, em que D corresponde a ordem de integração sazonal, $\Phi_P(L^S) = (1 - \Phi_1 L^S - \Phi_2 L^{2S} - \dots - \Phi_P L^{PS})$ é o operador sazonal *AR*(p), enquanto $\Theta_Q(L^S) = (1 - \Theta_1 L^S - \Theta_2 L^{2S} - \dots - \Theta_Q L^{QS})$ é o operador *MA*(q). Por fim, destaca-se que S denota a periodicidade sazonal, de maneira que $S = 6$ corresponde a sazonalidade semestral em uma série mensal e $S = 12$, caso a periodicidade seja anual.

3.2.3 Identificação

A etapa de identificação consiste na adoção de uma série de critérios de seleção para determinar qual dos diversos possíveis modelos $SARIMA(p, d, q)(P, D, Q)$ se ajusta melhor ao comportamento temporal das variáveis. Do ponto de vista teórico, a adição de defasagens nos vetores autorregressivos e de médias móveis reduzem a soma do quadrado dos resíduos estimados, porém, de outro lado à necessidade de estimação de coeficientes adicionais diminui o número de graus de liberdade e potencialmente reduz a performance preditiva de um modelo já ajustado (ENDERS, 2004).

Os três métodos mais populares para seleção de modelos são o de Box e Jenkins, o critério de informação de Akaike (AIC) e o critério de informação bayesiano de Schwarz (SBC).

O método de Box e Jenkins consiste na visualização gráfica das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) sobre as séries originais e diferenciadas – de acordo com a ordem de integração $I(d)$ – para determinar a ordem de p e q .

Já os critérios de seleção de Akaike e Schwarz sugerem que o processo de identificação seja realizado a partir de uma especificação estatística que leva em consideração a soma do quadrado dos resíduos da estimação (SSR), o número de parâmetros estimados ($n = p + q + \text{termo constante}$) e o número de observações temporais (T), seguindo as fórmulas:

$$AIC = T \ln(SSR) + 2n \quad (3)$$

$$SBC = T \ln(SSR) + n \ln(T) \quad (4)$$

3.2.4 Estimação e Checagem do Modelo

Selecionada a estrutura do modelo $SARIMA(p, d, q)(P, D, Q)$, o passo seguinte consiste na estimação e checagem dos coeficientes do modelo, de modo a verificar se o modelo adotado possui as propriedades desejáveis.

O estudo partirá da hipótese de que se os erros de previsão um passo a frente – onde utiliza-se as informações disponíveis até o período t para prever o valor em $t + 1$

– seguirem um processo de ruído branco, então o modelo será considerado adequado. Neste estágio, a proposição levantada será testada através do teste de Bartlett's, método que é baseado nas características do periodograma cumulativo no domínio da frequência.

Será performado também o teste de Ljung-Box, que checa se os resíduos estimados dos modelos ARMA seguem um processo de ruído branco através da inspeção de suas autocovariâncias. A hipótese nula do teste é a de que os resíduos são *i.i.d.*.

3.2.5 Previsão

Na última etapa, serão realizadas previsões de até h passos a frente para os modelos ajustados, segundo os critérios pré-estabelecidos anteriormente:

$$y_{t+h|t} = E_t(y_{t+h}|\Omega_t) \quad (5)$$

Onde $y_{t+h|t}$ representa a previsão realizada h passos a frente para a série temporal y , E_t denota o operador esperança, e Ω_t indica o conjunto de informações disponíveis no período onde a previsão é realizada.

No sentido de comparar a acurácia das previsões dos modelos, serão utilizados a raiz do erro quadrático médio (REQM), o erro absoluto médio (EAM) e o coeficiente de desigualdade de Theil (TIC), que são calculados da seguinte forma:

$$REQM = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_{t+h} - y_{t+h|t})^2} \quad (6)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |y_{t+h} - y_{t+h|t}| \quad (7)$$

$$TIC = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (y_{t+h} - y_{t+h|t})^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T y_{t+h}^2 + \frac{1}{T} \sum_{t=1}^T y_{t+h|t}^2}} \quad (8)$$

Onde y_{t+h} representa o valor observado, $y_{t+h|t}$ representa a previsão realizada h passos à para y , e T indica o número de observações fora da amostra.

4 RESULTADOS

Este capítulo destina-se à análise dos modelos de previsão das séries de ICMS e IPVA no Estado do Ceará. Para cumprir o determinado fim, realizaram-se as etapas de identificação, estimação, checagem e previsão dos modelos de acordo com a metodologia proposta no capítulo anterior.

Inicialmente serão realizados os testes de raiz unitária para determinar qual tipo de transformação, se necessária, garante a estacionariedade em média e variância das variáveis de interesse. Nesse estágio, determina-se a ordem de integração das séries.

Em seguida, através da metodologia de *Box e Jenkins* serão identificadas as ordens dos parâmetros autorregressivos e de média móvel (p e q , respectivamente), bem como a ordem de sazonalidade dos parâmetros autorregressivos e de média móvel (sar e sma , respectivamente).

A terceira etapa corresponderá a estimação e checagem de ambos modelos estimados, verificando se os mesmos seguem um processo de ruído branco. Caso a hipótese supracitada seja confirmada, prossegue-se com a análise da performance de previsão do modelo ajustado, caso contrário, retorna-se ao estágio anterior.

Por fim, serão utilizadas as medidas supracitadas no sub-capítulo 3.2.4 para avaliar a acurácia preditiva dos modelos de previsão realizados.

4.1 TESTE DE RAIZ UNITÁRIA

O primeiro passo para a identificação dos modelos ARIMA consiste na determinação da ordem de integração (d) das séries. Na formulação de modelos autorregressivos a proposição de estacionariedade é considerada uma condição necessária para a garantia das propriedades desejáveis de estimação.

Formalmente, um processo estocástico é dito estacionário se possui média finita, e se sua variância é estacionária em covariância, de modo que para todo t e $t - s$:

$$E(y_t) = E(y_{t-s}) = \mu \quad (9)$$

$$E[(y_t - \mu)^2] = \sigma^2 \quad (10)$$

$$E[(y_t - \mu)(y_{t-s} - \mu)] = E[(y_{t+s} - \mu)(y_t - \mu)] = \gamma_s \quad (11)$$

Onde μ , σ^2 e γ_s são todos parâmetros constantes. Ou seja, uma série temporal é estacionária se sua média e variância são invariantes no tempo e se o processo de autocovariância é função somente da distância entre as observações temporais, e não do tempo de origem das mesmas (Enders, 2004).

Para testar tal proposição, a presente dissertação realizará o teste de raiz unitária Dickey-Fuller aumentado (ADF). O ADF testa a hipótese nula de que uma série temporal y_t é integrada de ordem I(1) contra a hipótese alternativa de que a mesma seja estacionária I(0), assumindo que a dinâmica dos dados segue uma estrutura ARMA. Algebricamente, a estimação do teste é baseada na seguinte regressão linear:

$$y_t = \beta_0 D_t + \varphi_1 y_{t-1} + \sum_{j=1}^p \Delta y_{t-j} + \varepsilon_t \quad (11)$$

Onde D_t é um vetor de componentes determinísticos (constante, tendência, etc.). Enquanto o operador Δ denota a primeira diferença cuja é realizada para as p defasagens utilizadas, que garantem a ausência de correlação serial com o resíduo ε_t . Sob a hipótese nula y_t segue um processo não estacionário, o que implica que $\varphi_1 = 1$.

A escolha do número de defasagens para a implantação do teste foi determinada de acordo com o critério de Schwert (1989), cujo determina o número máximo de defasagens ($p_{máx}$) de acordo com a seguinte regra:

$$p_{máx} = \left\lceil 12 \cdot \left(\frac{T}{100} \right)^{\frac{1}{4}} \right\rceil \quad (12)$$

Onde $p_{máx}$ indica um número inteiro de defasagens e T o número de observações temporais disponíveis. Visto que a amostra é composta por 216 observações, então o número de defasagens máximo é igual a 14. Definido o número de defasagens máxima, adotou-se o critério de Schwarz para definir o número de defasagens ótima.

De acordo com a Tabela 1, ambas séries – ICMS e IPVA – são integradas de ordem 1 – I(1) –, uma vez que a hipótese nula não pode ser rejeitada a um nível de 5% de

significância para as variáveis em nível, mas rejeitou-se a hipótese nula para as variáveis em primeira diferença ao mesmo nível de significância, ou seja, as séries temporais do ICMS e IPVA são estacionárias em primeira diferença ($d = 1$).

Tabela 1: Teste de Raiz Unitária, Dickey-Fuller Aumentado (ADF)

Série	Componentes Determinísticos	Número de Defasagens	Estatística do Teste	p – valor
ICMS	Constante	11	-1.96	0.30
Δ ICMS	-	0	-18.85*	0.00
IPVA	Constante	13	-1.06	0.73
Δ IPVA	-	14	-2.81*	0.005

Fonte: Elaborada pela autora.

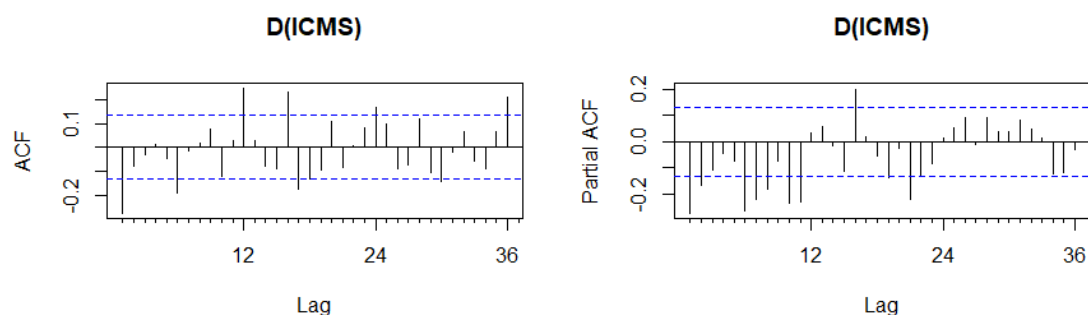
Nota 1: * estatística significativa a um nível de 5%.

4.2 IDENTIFICAÇÃO DOS MODELOS AJUSTADOS

Para realizar a identificação do modelo $ARIMA(p, d, q)$ que indica o melhor comportamento para cada uma das variáveis de interesse inicialmente serão analisadas a Função Autocorrelação (FAC) e a Função Autocorrelação Parcial (FACP) das séries em primeira-diferença, para tentar determinar os possíveis candidatos a modelos ajustados.


Conforme pode ser observado pela Figura 2, a Função ACF indica que o componente de média movel (MA) decai rapidamente após o primeiro período, porém volta a se tornar estatisticamente maior do que zero periodicamente, o que indica a presença de sazonalidade no componente até 24 períodos depois. Já a função FACP indica que o componente autoregressivo decai após 2 períodos com a presença também de comportamento periódico da função, sugerindo a presença de sazonalidade. Diante desse comportamento, serão utilizados como possíveis candidatos para a previsão do ICMS, os modelos $SARIMA(p, d, q)(P, D, Q)_{12}$ com $p[0,3]$, $q[0,2]$, $D[0,2]$ e $Q[0,2]$.

Figura 2: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) do ICMS.



Fonte: Elaborada pela autora.

Figura 3: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) do IPVA.



Fonte: Elaborado pela autora

Já a FAC e FACP, construídas para a primeira diferença do IPVA, indicam a forte presença do componente sazonal. Observa-se sazonalidade forte para a média móvel (Q) em um período de 24 meses, enquanto que a FACP sugere sazonalidade em apenas 12 meses para o componente autoregressivo (P).

Assim, os possíveis modelos $SARIMA(p, d, q)(P, D, Q)_{12}$ candidatos possuirão defasagens $p[0,2]$, $q[0,2]$, $D[0,1]$ e $Q[0,2]$.

Estabelecidos os possíveis candidatos, os critérios de informação de Akaike (AIC) e de Schwarz (SBC) foram utilizados para identificar qual dos possíveis modelos é o mais adequado para a realização da previsão para as séries temporais.

Com relação a série temporal ICMS, foram estimados 193 possíveis modelos, e, de acordo com o critério AIC, foi escolhido o modelo $SARIMA(2,1,1)(1,0,1)_{12}$, enquanto o critério SBC selecionou um modelo mais parcimonioso - $SARIMA(1,1,1)(1,0,1)_{12}$. Tal resultado já era esperado, haja vista que o modelo AIC tende a selecionar um modelo sobreparametrizado, no entanto, para pequenas amostras, o AIC tende a gerar modelos mais eficientes do que o SBC (Enders, 2004). Diante disso, a presente dissertação utilizará ambos os modelos no processo de estimação, checagem e previsão para o ICMS.

Estimaram-se 145 possíveis modelos para a variável IPVA, o critério AIC selecionou o modelo $SARIMA(2,1,2)(1,0,1)_{12}$, enquanto o critério SBC sugeriu o modelo $SARIMA(2,1,1)(1,0,1)_{12}$. Novamente, optou-se por proceder com a escolha de ambos modelos para a análise das próximas etapas.

4.3 ESTIMAÇÃO E CHECAGEM DOS RESÍDUOS

Identificados os modelos que apresentaram melhores comportamentos de acordo com os critérios de informação utilizados, neste subcapítulo serão realizadas as estimações dos modelos selecionados e a checagem dos resíduos para verificar se os modelos ajustados são adequados para o processo preditivo.

4.3.1 ICMS

Com relação a arrecadação tributária do ICMS, a tabela abaixo resume as estimações realizadas para os modelos $SARIMA(2,1,1)(1,0,1)_{12}$ e $SARIMA(1,1,1)(1,0,1)_{12}$.

Tabela 2: Modelos Estimados para o ICMS

Modelos	$SARIMA(2,1,1)(1,0,1)_{12}(AIC)$	$SARIMA(1,1,1)(1,0,1)_{12}(SBC)$
AR (1)	0.206* (0.082)	0.190* (0.075)
AR (2)	0.064 (0.083)	
MA (1)	-0.830* (0.008)	-0.804* (0.013)
SAR (12)	0.997* (0.013)	0.998* (0.013)
SMA (12)	-0.933* (0.160)	-0.943* (0.188)
Observações	215	215
R ²	0.42	0.42

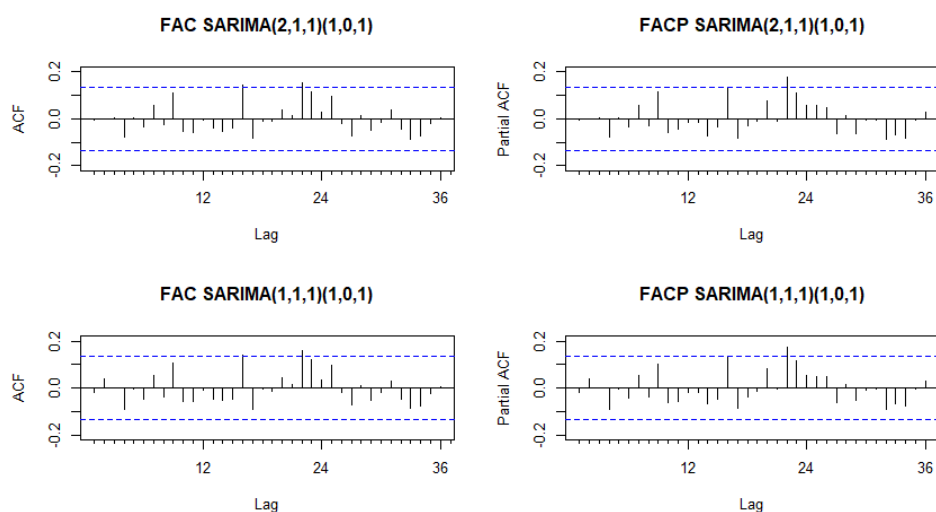
Fonte: Elaborado pela autora.

Nota 1: * Significante a um nível de 5%.

Conforme pode ser observado acima, somente o coeficiente estimado para o componente AR(2) no modelo $SARIMA(2,1,1)(1,0,1)_{12}$ demonstrou-se não significativo a um nível de 5% de significância, o que pode estar relacionado a sobreparametrização relacionada ao critério de informação AIC citada pela literatura.

No intuito de verificar se os modelos estão bem especificados, foram realizados testes estatísticos sobre os resíduos das estimações, assim como a inspeção visual das funções FAC e FACP residual. Os testes escolhidos foram o teste de Bartlett's, que investiga se os resíduos seguem um processo de ruído branco, e o teste de Ljung Box, para investigar se a autocorrelação serial dos resíduos foi expurgada.

Figura 4: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) dos resíduos – ICMS.



Fonte: Elaborado pela autora

O correlograma dos resíduos de ambas estimações indica que os mesmos seguem um processo de ruído branco, havendo apenas um período nas funções FAC e FACP dos modelos em que os resíduos encontram-se fora do limite estipulado.

A Tabela 3 indica os resultados dos testes realizados sobre os resíduos estimados. Conforme fora citado no subcapítulo 3.2.3, tanto o teste de Bartlett's, quanto o teste de Ljung-Box possuem como hipótese nula a afirmativa de que os resíduos seguem um processo de ruído branco.

Tabela 3: Testes sobre os resíduos estimados

Série	Estatística Ljung-Box	<i>p</i> – valor	Estatística Bartlett's	<i>p</i> – valor
$SARIMA(2,1,1)(1,0,1)_{12}$	24.32	0.23	0.430	0.99
$SARIMA(1,1,1)(1,0,1)_{12}$	26.40	0.15	0.514	0.95

Fonte: Elaborado pela autora.

Nota: Hipótese Nula: Não existe autocorrelação serial nos resíduos.

De acordo com os resultados observados, identifica-se que os resíduos de ambos os modelos podem ser considerados processos de ruído branco, inexistindo autocorrelação serial. Dessa forma, infere-se que ambos modelos possuem as propriedades necessárias para o processo de previsão da série do ICMS.

4.3.2 IPVA

Abaixo pode-se visualizar em detalhes o resultado das regressões dos modelos indicados pelos critérios de informação para a modelagem do comportamento temporal da arrecadação tributária do IPVA. O modelo $SARIMA(2,1,2)(1,0,1)_{12}$ foi o que minimizou o critério de informação de Akaike, enquanto o modelo $SARIMA(2,1,1)(1,0,1)_{12}$ foi o selecionado pelo critério de Schwarz.

Tabela 4: Modelos Estimados para o IPVA

Modelos	$SARIMA(2,1,2)(1,0,1)_{12}$	$SARIMA(2,1,1)(1,0,1)_{12}$
AR (1)	-0,180 (0,202)	0,179* (0,068)
AR (2)	0,309* (0,066)	0,246* (0,070)
MA (1)	-0,596* (0,200)	-0,981* (0,021)
MA (2)	-0,373* (0,188)	
SAR (12)	0,994* (0,004)	0,994* (0,004)
SMA (12)	-0,322* (0,055)	-0,308* (0,054)
Observações	215	215
R ²	0,97	0,97

Fonte: Elaborado pela autora.

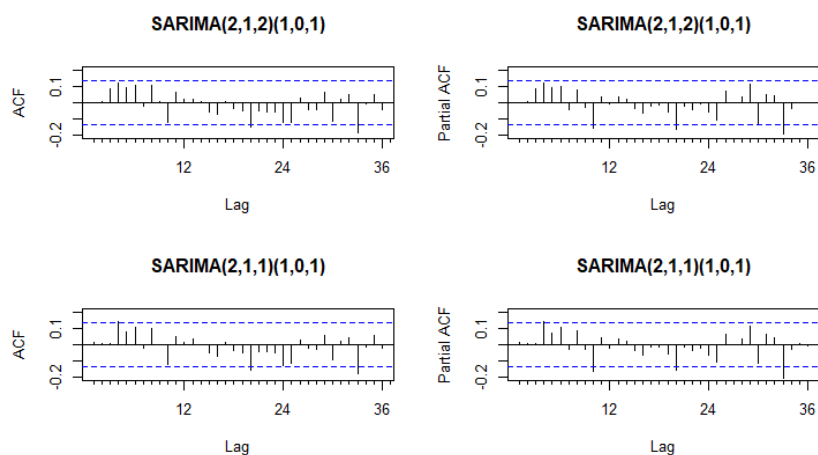
Nota 1: * Significante a um nível de 5%.

Assim como no caso da estimação dos modelos associados ao ICMS, o modelo associado ao critério de informação SBC apresentou todos os coeficientes estimados estatisticamente significantes. Já para o modelo selecionado via critério AIC, o coeficiente estimado para o modelo $AR(1)$ foi o único que não se apresentou estatisticamente significativo a um nível de 5% de significância.

Através da inspeção visual do correlograma dos resíduos, observa-se novamente um padrão muito próximo entre ambos modelos estimados. As funções FAC e FACP sugerem em ambos casos que os resíduos seguem um processo de ruído branco,

no intuito de confirmar a hipótese levantada. A seguir segue o resultado dos testes de Ljung-Box e Bartlett's.

Figura 5: Função Autocorrelação (FAC) e Função Autocorrelação Parcial (FACP) dos resíduos - IPVA.



Fonte: Elaborado pela autora

Tabela 5: Testes sobre os resíduos estimados - IPVA

Série	Estatística Ljung-Box	$p - valor$	Estatística Bartlett's	$p - valor$
$SARIMA (2,1,2)(1,0,1)_{12}$	27.54	0.23	0.687	0.73
$SARIMA (2,1,1)(1,0,1)_{12}$	25.83	0.31	0.587	0.88

Fonte: Elaborado pela autora.

Logo, assim como no caso dos modelos estimados para o ICMS, a análise dos resíduos estimados não sugeriu a rejeição de ambos modelos ajustados para o IPVA, uma vez que os testes indicaram que os resíduos seguem um processo de ruído branco, sendo identicamente e independentemente distribuídos.

4.4 PREVISÃO

Este subcapítulo apresenta o exercício de previsão para as séries de arrecadação tributária mensal do ICMS e do IPVA para o Estado do Ceará. O horizonte de previsão adotado foi de doze meses, compreendendo o período entre janeiro de 2016 até dezembro de 2016, período cujas informações já estão disponibilizadas, mas que foram intencionalmente deixadas de fora do processo de identificação e estimação dos modelos ajustados.

Tal processo de previsão caracteriza-se como previsão para fora da amostra, onde se utiliza uma parte da amostra disponível (1998:01 – 2015:12) para estimar o modelo e então realiza-se a previsão para o restante das observações (2016:01 – 2016:12).

4.4.1 Análise de Previsão - ICMS

A Tabela 6 traz as informações acerca das previsões realizadas para fora da amostra para o ICMS, bem como a comparação entre os valores previstos e os valores observados para o período de análise.

Tabela 6: Previsão de arrecadação mensal do ICMS para fora da amostra

Período	Valores Previstos		Valor Observado	Diferencial Percentual (AIC)	Diferencial Percentual (SBC)
	<i>SARIMA</i> (2,1,1)(1,0,1) ₁₂ (AIC)	<i>SARIMA</i> (1,1,1)(1,0,1) ₁₂ (SBC)			
2016:01	883.886.828,16	884.003.008,16	866.185.793,36	2,04	2,06
2016:02	829.866.371,12	832.164.077,67	830.362.158,38	-0,06	0,22
2016:03	794.845.356,91	793.618.563,43	806.627.987,70	-1,46	-1,61
2016:04	842.942.618,20	840.662.148,66	841.214.891,00	0,21	-0,07
2016:05	835.970.244,75	834.358.304,54	825.345.997,53	1,29	1,09
2016:06	846.665.355,92	843.784.840,34	841.738.682,42	0,59	0,24
2016:07	877.857.168,95	875.333.294,15	864.702.993,62	1,52	1,23
2016:08	938.426.693,70	936.855.217,63	901.755.876,02	4,07	3,89
2016:09	958.089.858,98	955.523.240,34	913.146.809,71	4,92	4,64
2016:10	960.341.040,23	957.643.536,61	898.854.126,42	6,84	6,54
2016:11	968.383.554,57	965.648.988,97	908.188.092,09	6,63	6,33
2016:12	1.026.152.650,68	1.024.866.301,08	938.026.539,00	9,39	9,26

Fonte: Elaborada pela autora.

Nota 1: Os valores previstos foram recuperados ao tomar o exponencial das previsões estimadas.

Nota 2: O Diferencial percentual é calculado a partir da seguinte equação: $\left[\left(\frac{\text{Valor Previsto}}{\text{Valor Observado}} - 1\right) * 100\right]$

Globalmente, em ambos casos, as previsões demonstraram-se especialmente satisfatórias até um horizonte de sete meses a frente, com sua capacidade preditiva decaindo ao final da amostra. Observa-se que o modelo *SARIMA* (2,1,1)(1,0,1)₁₂ apresentou em termos absolutos o menor diferencial percentual (-0,06%) e o maior diferencial percentual (9,39%). Apesar disso, observa-se uma qualidade de ajustamento muito próxima entre ambos modelos.

No intuito de comparar a acurácia das previsões dos modelos, na Tabela 7 são confrontados a raiz do erro quadrático médio (REQM), o erro absoluto médio (EAM) e o coeficiente de desigualdade de Theil (TIC) de ambos modelos *SARIMA* (2,1,1)(1,0,1)₁₂ e *SARIMA* (1,1,1)(1,0,1)₁₂.

Tabela 7: Medidas de eficiência de Previsão - ICMS

Período	Valores Previstos	
	$SARIMA (2,1,1)(1,0,1)_{12}$ (AIC)	$SARIMA (1,1,1)(1,0,1)_{12}$ (SBC)
<i>EAM</i>	0.031613	0.030145
<i>REQM</i>	0.042341	0.040916
<i>TIC</i>	0.001028	0.00993

Fonte: Elaborado pela autora.

Comparando as grandezas das medidas clássicas de eficiência de previsão, observa-se que o modelo $SARIMA (1,1,1)(1,0,1)_{12}$ (SBC) foi robustamente mais eficiente que o modelo $SARIMA (2,1,1)(1,0,1)_{12}$ (AIC), uma vez que apresentou valores inferiores de acordo com as três medidas de eficiência de previsão utilizadas na presente dissertação.

4.4.2 Análise de Previsão - IPVA

Seguindo o processo de análise de previsão, a Tabela 8 denota as previsões mensais de arrecadação do IPVA de acordo com os modelos $SARIMA (2,1,2)(1,0,1)_{12}$ (AIC) e $SARIMA (2,1,1)(1,0,1)_{12}$ (SBC). Pode-se observar uma maior volatilidade na diferença entre os valores previstos de ambos modelos e os valores observados, com o menor valor absoluto do Diferencial Percentual sendo de 0,10% e maior valor absoluto do Diferencial Percentual de 24,82%.

Através da comparação do Diferencial Percentual calculado observa-se também que o modelo $SARIMA (2,1,1)(1,0,1)_{12}$ (SBC) apresentou valores mais próximos dos valores observados em nove períodos – exceto para os períodos de 2016:05, 2016:06 e 2016:11 - possuindo também o menor valor absoluto do Diferencial Percentual (0,10), enquanto o modelo $SARIMA (2,1,2)(1,0,1)_{12}$ (AIC) apresentou o maior valor (24,82).

Tabela 8: Previsão de arrecadação mensal do IPVA para fora da amostra (2016:01 – 2016:12)

Período	Valores Previstos		Valor Observado	Diferencial Percentual (AIC)	Diferencial Percentual (SBC)
	<i>SARIMA</i> (2,1,2)(1,0,1) ₁₂ (AIC)	<i>SARIMA</i> (2,1,1)(1,0,1) ₁₂ (SBC)			
2016:01	217.857.632,50	217.446.014,60	197.413.922,26	10,36	10,14
2016:02	116.370.296,13	115.501.128,18	113.917.677,35	2,15	1,39
2016:03	107.983.013,47	106.088.596,46	105.983.766,58	1,89	0,10
2016:04	100.630.668,69	100.128.689,79	90.705.275,78	10,94	10,39
2016:05	87.831.421,12	87.003.514,12	88.632.819,53	-0,90	-1,84
2016:06	30.229.891,89	30.195.761,96	34.683.424,51	-12,84	-12,94
2016:07	27.754.105,10	27.623.263,31	23.605.120,54	17,58	17,02
2016:08	21.031.623,51	21.002.408,00	19.876.878,29	5,81	5,66
2016:09	18.343.495,22	18.290.252,70	14.696.469,71	24,82	24,45
2016:10	14.826.876,93	14.804.443,79	12.908.663,43	14,86	14,68
2016:11	12.341.399,04	12.312.569,18	12.886.703,20	-4,23	-4,45
2016:12	14.131.311,70	14.098.919,24	13.922.708,76	1,50	1,26

Fonte: Elaborada pela autora.

Nota 1: Os valores previstos foram recuperados ao tomar o exponencial das previsões estimadas.

Nota 2: O Diferencial percentual é calculado a partir da seguinte equação: $[(\frac{\text{Valor Previsto}}{\text{Valor Observado}} - 1) * 100]$

Tabela 9: Medidas de eficiência de Previsão - IPVA

Período	Valores Previstos	
	<i>SARIMA</i> (2,1,2)(1,0,1) ₁₂ (AIC)	<i>SARIMA</i> (2,1,1)(1,0,1) ₁₂ (SBC)
<i>EAM</i>	0.085466	0,082801
<i>REQM</i>	0.108049	0,106246
<i>TIC</i>	0.003084	0.003033

Fonte: Elaborada pela autora.

O coeficiente de desigualdade de Theil (TIC) apresentou valores próximos de zero em ambos modelos, o que indica uma ótima capacidade de previsão do modelo em ambos casos. Comparativamente, o modelo *SARIMA* (2,1,1)(1,0,1)₁₂ (SBC) obteve uma melhor performance de acordo com a medida TIC (0,003033 contra 0,003084 do modelo *SARIMA* (2,1,2)(1,0,1)₁₂ (AIC)).

As demais métricas de eficiência de previsão (EAM e REQM) também confirmaram a hipótese de que o modelo *SARIMA* (2,1,1)(1,0,1)₁₂ (SBC) foi mais eficiente no processo de previsão do que o modelo *SARIMA* (2,1,2)(1,0,1)₁₂ (AIC).

5 CONSIDERAÇÕES FINAIS

A presente dissertação se propôs a identificar modelos de previsão baseados na metodologia de *Box e Jenkins* para a arrecadação tributária do ICMS e IPVA do Estado do Ceará. Além da capacidade preditiva dos modelos ajustados, avaliou-se também as propriedades dos regressores estimados, verificando se as mesmas atendiam as especificações desejáveis.

Os resultados mostram que os modelos selecionados através dos critérios de informação de Akaike e de Schwarz para ambas séries de interesse apresentaram-se consistentes do ponto de vista estatístico. Identifica-se que os resíduos estimados de ambos os modelos podem ser considerados processos de ruído branco, inexistindo autocorrelação serial.

Para o ICMS os resultados do processo de previsão de ambos modelos ajustados - $SARIMA(2,1,1)(1,0,1)_{12}(AIC)$ e $SARIMA(1,1,1)(1,0,1)_{12}(SBC)$ - demonstram uma maior acurácia no horizonte de sete meses. Nesse intervalo temporal, o diferencial percentual máximo foi de 2.06%, observado no período de janeiro de 2016 segundo o modelo $SARIMA(1,1,1)(1,0,1)_{12}(SBC)$.

As métricas de eficiência preditiva adotadas na presente dissertação indicaram que o modelo ajustado de acordo com o critério de Schwarz apresentou resultados robustamente superiores ao modelo ajustado via critério de Akaike, obtendo valores inferiores de acordo com as três medidas de eficiência de previsão.

Para o imposto IPVA os modelos estimados - $SARIMA(2,1,2)(1,0,1)_{12}(AIC)$ e $SARIMA(2,1,1)(1,0,1)_{12}(SBC)$ - apresentaram diferenciais percentuais mais elevados, se comparado com os modelos de previsão do ICMS. A maior volatilidade na diferença entre os valores previstos e os valores realizados deve-se em grande medida ao processo gerador dos dados, uma vez que a série possui simultaneamente tendência temporal e forte presença de sazonalidade, o que possivelmente dificultou o balanceamento do modelo.

No caso das métricas de eficiência preditiva, novamente as três medidas identificaram que o modelo ajustado de acordo com o critério de Schwarz apresentou melhor capacidade preditiva do que o modelo estimado a partir do critério de Akaike.

Ainda a respeito do desempenho dos modelos de previsão, a não significância de alguns coeficientes estimados pelo critério de Akaike indica que a maior acurácia preditiva do critério de Schwarz potencialmente deve-se ao sobreajuste dos dados

decorrente da adoção do primeiro critério. Enders (2004) identifica que na prática o critério de Schwarz seleciona modelos mais parcimoniosos do que o critério de Akaike, com boa capacidade de representação do processo gerador dos dados.

Em geral, os resultados sugerem a validade da utilização da metodologia ARIMA como ferramenta para realizar previsões da arrecadação tributária do Estado do Ceará, observando-se um melhor ajuste de modelos parcimoniosos ao comportamento temporal das séries de arrecadação.

REFERÊNCIAS

- ABRAHAM, B., LEDOLTER, J. **Statistical methods for forecasting** (Vol. 234). John Wiley & Sons, 2009.
- BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. Holden Day, San Francisco, 1976
- BRASIL. Lei Complementar nº 87, de 13 de Setembro de 1996.
- BRASIL. Lei nº 12.670, de 27 de Dezembro de 1996.
- BRASIL. Lei nº 12.023, de 20 de Novembro de 1992.
- BRASIL. Lei nº 13.417, de 30 de Dezembro de 2003.
- CAMARGOS, A.A.B. **Modelos de previsão da arrecadação tributária do estado de SÃO PAULO: ICMS, IPVA, ITCMD e TAXA**. Dissertação (Mestrado em Ciências Econômicas) – Faculdade Ibmec, São Paulo, 2008.
- CASTELAR, I.; FERREIRA, R. T.; LINHARES, F. C. Modelos de Previsão para o ICMS do Estado do Ceará. **Revista Economia do Nordeste**, v.27, n.4, p. 583-606, 1996.
- ENDERS, W. **Applied Econometrics Time Series: 4º Edition**. Technometrics, 2004.
- KAVANAGH, S. C., & Iglehart, C. Structuring the Revenue Forecasting Process. **Government Finance Review**, 2012.
- PESSOA, F. C.; CORONEL, D. A.; DE LIMA, J.E. Previsão de arrecadação de ICMS para o estado de Minas Gerais: uma comparação entre modelos Arima e Arfima. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 9, n. 2, 2013.
- SANTANA, A.L. **Previsões para arrecadação de ICMS no Ceará: uma análise com modelo de correção de erros**. Dissertação (Mestrado em Ciências Econômicas) – Universidade Federal do Ceará, Fortaleza, 2009.
- SILVESTRE, C.D. **Análise do ICMS no Estado do Ceará para o Período de 2000 a 2013**. Dissertação (Mestrado em Ciências Econômicas) – Universidade Federal do Ceará, Fortaleza, 2016.