



UNIVERSIDADE FEDERAL DO CEARÁ – UFC
CAMPUS AVANÇADO DE SOBRAL
CURSO DE CIÊNCIAS ECONÔMICAS

DEYSER DE OLIVEIRA DOS REIS

**MODELOS DE PREVISÃO PARA O ICMS DA MESORREGIÃO
NOROESTE DO ESTADO DO CEARÁ**

SOBRAL

2011

DEYSER DE OLIVEIRA DOS REIS

**MODELOS DE PREVISÃO PARA O ICMS DA MESORREGIÃO
NOROESTE DO ESTADO DO CEARÁ**

Monografia apresentada ao Campus de Sobral,
como requisito parcial para obtenção do grau de
Bacharel em Ciências Econômicas.

Orientador: Prof. Ms. Pablo Urano de Carvalho
Castelar.

SOBRAL-CE

2011

DEYSER DE OLIVEIRA DOS REIS**MODELOS DE PREVISÃO PARA O ICMS DA MESORREGIÃO NOROESTE DO
ESTADO DO CEARÁ**

Esta monografia foi submetida à Coordenação do Curso de Ciências Econômicas do *Campus* de Sobral, como parte dos requisitos necessários à obtenção do título de Bacharel em Ciências Econômicas, outorgado pela Universidade Federal do Ceará – UFC e encontra-se à disposição dos interessados na biblioteca da referida universidade.

A citação de qualquer trecho desta monografia é permitida, desde que feita de acordo com as normas de ética científica.

Aprovada em: 09 de junho de 2011.

NOTA

Prof. Ms. Pablo Urano de Carvalho Castelar
Universidade Federal do Ceará – *Campus* de Sobral
Prof. Orientador

NOTA

Prof. Dr. Francis Carlo Petterini Lourenço
Universidade Federal do Ceará – *Campus* de Sobral
Membro da Banca Examinadora

NOTA

Prof. Dr. Vitor Borges Monteiro
Universidade Federal do Ceará – *Campus* de Sobral
Membro da Banca Examinadora

A Deus, minha família e amigos, sem os quais não teria chegado onde estou e, certamente, não teria motivos para continuar.

AGRADECIMENTOS

Primeiramente, agradeço a Deus e a Nossa Senhora de Fátima, por tudo de maravilhoso que já me proporcionaram e em especial por todas as lições e reflexões, que me fizeram crescer, pela saúde, pela fé e por todos os motivos de minha existência: meus pais, irmãos, família e amigos.

Aos meus pais, José Ribamar de Oliveira e Francisca Amélia dos Reis Oliveira, por todo o amor, carinho, dedicação, incentivo, compreensão, ensinamentos e, principalmente, pelo sacrifício feito em prol da minha educação. Jamais poderei expressar em palavras minha gratidão, admiração e amor por vocês.

Aos meus irmãos Diana Oliveira e Rubens de Oliveira, pelo amor, compreensão e incentivo. E ao meu cunhado Elisângelo Oliveira, presente em vários momentos importantes da minha vida como um irmão.

Ao meu namorado Robson Bandeira, com quem tenho compartilhado momentos maravilhosos, por seu incentivo, companheirismo, paciência e amor.

Ao Professor e Orientador, Pablo Castelar, por sua atenção, paciência, ensinamentos, confiança e contribuições que tornaram possíveis a conclusão deste trabalho.

Às professoras e amigas Kílvia Mesquita e Sâmia Maluf por todos os ensinamentos, incentivos, oportunidades, paciência, confiança, carinho, e, principalmente, por todas as preocupações com minha formação.

Aos amigos Fidel Viana, Maximilo Ribeiro, Roberto Bruno Nepomuceno, Carla Passos, Cleidiane Marques, Silvia de Souza, Rosiane Alves, Jakeline Farias, Acélio Mesquita, Jonathas Lima, Gleyson Silva, Edianny Lima, Tobias Reis, Nayara Asano, Deyvid Kardec, Thiago Matos, Crisneive Silveira, Renan Dantas e demais amigos e amigas que tornam minha vida repleta de alegrias.

Aos companheiros de turma Maitê Shirrasu, Felipe Bastos, Crislene Matias, Joyciane Coelho, Thalita Oliveira, Wendel Mendes, Priscila Porto, Nathan Viana, Daniel Gomes, aos que se uniram a nós no percurso Irani Martins, Kaliny Kélvia, Bruna Janielle e Paulo Roberto e aos demais que fizeram parte da nossa turma, por toda confiança, respeito, incentivo e amizade, que ficarão para sempre.

Aos professores: Ivan Castelar, Vitor Borges, Francis Petterini, Salvelina Lourenço, aos demais professores, e a todos que fazem parte do *Campus* de Sobral, pelos ensinamentos dentro e fora de sala de aula.

"Bom mesmo é ir à luta com determinação, abraçar a vida e viver com paixão, perder com classe e vencer com ousadia, pois o triunfo pertence a quem se atreve... E a vida é muito para ser insignificante." (Charles Chaplin)

RESUMO

Este estudo consiste em uma análise de séries temporais para previsão trimestral do imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação (ICMS) da Mesorregião Noroeste do Estado do Ceará. Objetiva-se abordar diferentes metodologias de análise de séries temporais para fornecer aos gestores públicos diferentes modelos de previsão consistentes e com satisfatório poder preditivo, que possam contribuir de forma auxiliar no desenvolvimento de políticas públicas e no aumento do bem-estar econômico municipal, regional e estadual do Ceará. Para atingir o objetivo traçado, foram utilizados: os modelos ARIMA, alisamento exponencial, função de transferência e combinação de previsões para realização de previsões. O trabalho inicia-se com a análise do ICMS, seguida por uma revisão de literatura onde são abordados os modelos teóricos utilizados, bem como os resultados empíricos obtidos no estudo. Ao final, observa-se que os resultados apresentados corroboram com postulados de trabalhos semelhantes realizados sobre o tema, o que confirma a relevância dos modelos utilizados na análise de séries temporais e sua importância como instrumentos de predição.

Palavras-chave: ICMS, Mesorregião Noroeste do Ceará, séries temporais, modelos de previsão.

ABSTRACT

This study consists of a time series analysis for quarterly forecasting of the tax on circulation of goods and on rendering of services on an interstate and intermunicipal level (ICMS) for the Northwestern region of the State of Ceará. The objective is to address different time series analysis methodologies, in order to provide different models for public managers for prediction and consistent with satisfactory predictive power, which can contribute to help the development of public policies and increased the municipal and regional economic welfare for the state of Ceará. To achieve this goal, the following techniques were used: ARIMA models, Exponential Smoothing, Transfer Function and the combination of forecasts for prediction. This work begins with an analysis of the ICMS tax, followed by a review of the literature which addresses the theoretical models used, as well as the empirical results obtained in the study. Lastly, it is observed that the results achieved corroborate the postulates of similar studies conducted on the subject, which confirm the relevance of the models used in time series analysis and its importance as instruments of prediction.

Keywords: ICMS, Northwestern region of the Ceará state, time series, forecast models

LISTA DE FIGURAS E GRÁFICOS

Figura 1 – Histograma da série	30
Gráfico 1 – Série Temporal do ICMS – valores reais	13
Gráfico 2 – Série Temporal do ICMS – valores reais	29
Gráfico 3 – Série Temporal do ICMS estacionaria	31
Gráfico 4 – Valores realizados e estimados pelo ARIMA (1,1,3) – período de janeiro de 2001 a dezembro de 2010	34
Gráfico 5 – Valores realizados e estimados pelo alisamento exponencial multiplicativo – período de janeiro de 2001 a dezembro de 2010	36
Gráfico 6 – Correlação ICMS x FPM – período de Janeiro de 2001 a Dezembro de 2010	37
Gráfico 7 – Valores realizados e estimados com base na função de transferência – período de janeiro de 2001 a dezembro de 2010	38
Gráfico 8 – Valores realizados e estimados com os modelos ARIMA (1,1,3), Alisamento exponencial Multiplicativo e Função de Transferência – período de janeiro de 2001 a março de 2011	39
Gráfico 9 – Valores realizados e estimados com base na combinação de previsões – período de janeiro de 2001 a março de 2011	40

LISTA DE TABELAS

Tabela 1 – Padrões teóricos das funções de autocorrelação e autocorrelação parcial	19
Tabela 2 – Teste de Raiz Unitária (ADF)	31
Tabela 3 – Correlograma da série temporal do ICMS estacionária	32
Tabela 4 – Equação estimadas para modelar a série temporal do ICMS e Critérios de Akaike e Schwarz do ARIMA	32
Tabela 5 – Comparação da eficiência dos modelos na previsão <i>ex-post</i>	33
Tabela 6 – Correlograma dos resíduos do ARIMA (1,1,3)	33
Tabela 7 – Comparação dos EPAM para a escolha do modelo de alisamento exponencial ...	35
Tabela 8 – Critérios de Akaike e Schwarz para os modelos de Função de Transferência	37
Tabela 9 – Valor realizado, valores previstos e EPAM do ICMS regional	38
Tabela 10 – Valor realizado e previstos do ICMS regional trimestral	40

SUMÁRIO

LISTA DE FIGURAS E GRÁFICOS	9
LISTA DE TABELAS	10
1. INTRODUÇÃO	12
2. REFERENCIAL TEÓRICO.....	15
2.1 Estudos na área de previsão do ICMS	15
2.2 Métodos de previsão.....	16
2.3 Modelos ARIMA	17
2.4 Modelos de alisamento exponencial	22
2.5 Modelos de função de transferência	24
2.6 Combinação de previsão	25
2.7 Medidas de eficiência de previsões	26
3. RESULTADOS EMPÍRICOS.....	29
3.1 Base de dados	29
3.2 Teste de raiz unitária	30
3.3 ARIMA	32
3.4 Alisamento exponencial	35
3.5 Função de transferência	36
3.6 Previsões	38
3.7 Combinação de previsões	39
4. CONCLUSÕES.....	41
REFERÊNCIAS	42
APÊNDICES	44

1. INTRODUÇÃO

O imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação (ICMS) é um tributo que representa grande parte da arrecadação tributária nacional, e somente os estados e o Distrito Federal têm competência para instituí-lo, de acordo com o art. 155, inciso II da Constituição Federal de 1988 e a Lei Complementar (LC) nº 87/96, denominada de Lei Kandir.

Onde é determinado na LC nº 87/96 que:

Art. 1º Compete aos Estados e ao Distrito Federal instituir o imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação, ainda que as operações e as prestações se iniciem no exterior.

E que, segundo Holanda et al. (2007, p. 4):

O artigo 158 da Constituição Federal dispõe, em seu inciso IV, que 25% do produto da arrecadação do Imposto do Estado sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação (ICMS), pertence aos municípios.

Ainda conforme determinação na Constituição de 1988, com relação à parcela destinada aos municípios, 75% (três quartos) no mínimo é relativo à proporção do valor adicionado nas operações relativas à circulação de mercadorias e nas prestações de serviços que tenham sido realizadas no seu território e até 25% (um quarto), conforme disposto em lei estadual.

No Estado do Ceará encontra-se regulamentado na Lei Estadual 14.023/07 que alterou a Lei 12.612/96 e no Decreto 29.306/08, onde consta que:

Art.1º Os critérios de distribuição da parcela de 25% (vinte e cinco por cento) do produto da arrecadação do ICMS pertencente aos Municípios cearenses regem-se pelo disposto na Lei estadual nº 12.612, de 7 de agosto de 1996, com a redação dada pela Lei nº14.023, de 17 de dezembro de 2007, regulamentada por este Decreto.

Parágrafo único. A parcela de que trata o caput será apurada e distribuída com observância aos percentuais seguintes:

I - 75% (setenta e cinco por cento) referente ao Valor Adicionado Fiscal - VAF;

I - 18% (dezoito por cento) em função do Índice Municipal de Qualidade Educacional de cada município, formado pela taxa de aprovação dos alunos do 1º ao 5º ano do ensino fundamental e pela média obtida pelos alunos de 2º e 5º ano da rede municipal em avaliações de aprendizagem;

III - 5% (cinco por cento) em função do Índice Municipal de Qualidade da Saúde de cada município, formado por indicadores de mortalidade infantil;

IV - 2% (dois por cento) em função do Índice Municipal de Qualidade do Meio Ambiente de cada município, formado por indicadores de boa gestão ambiental.

De acordo com as regulamentações expostas, pode-se observar que a distribuição dos recursos referentes à arrecadação do ICMS aos municípios privilegia o valor adicionado (três quartos), o que beneficia os municípios com elevados movimentos econômicos, agindo também como importante impulso para a atividade econômica municipal, regional e estadual. Ressalta-se também que, as transferências do ICMS constituem para os municípios parte substanciais de suas receitas.

O Gráfico 1 apresenta a arrecadação do ICMS por Mesorregiões geográficas¹ do Estado do Ceará de 2010, que conforme determinação do Instituto Brasileiro de Geografia e Estatística (IBGE) encontram-se representados por: Noroeste, Norte, Região Metropolitana, Sertões, Jaguaribe, Centros-Sul e Sul.

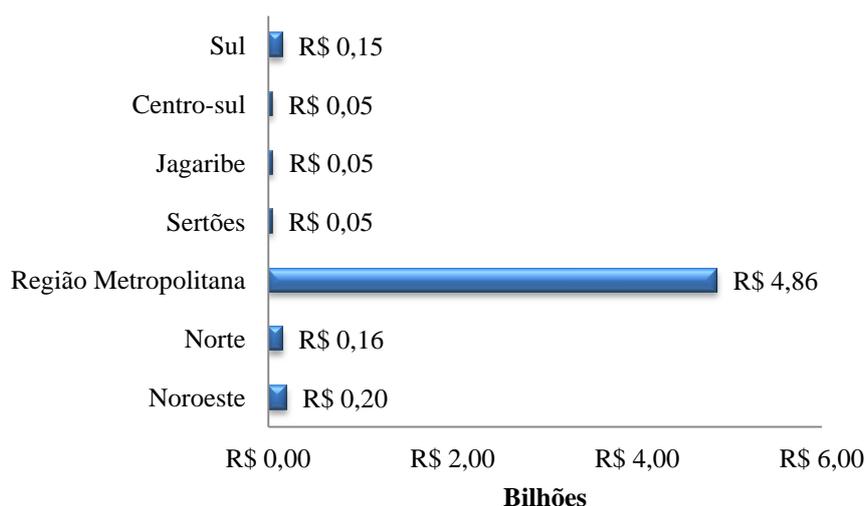


Gráfico 1 – Arrecadação do ICMS por Mesorregiões do Estado do Ceará de 2010.

Fonte: elaborado pela autora a partir da base de dados.

¹ Sobre a divisão do estado do Ceará ver IPECE: <http://www2.ipece.ce.gov.br/atlas/capitulo1/11/129x.htm>

Onde a maior parcela da arrecadação do Estado concentra-se na Região Metropolitana (4,8 bilhões), seguido pelo Noroeste (0,20 bilhões), Norte (0,16 bilhões), Sul (0,15 bilhões), Centro-sul, Jaguaribe e Sertões (0,05 bilhões cada).

Além disso, legalmente existe a exigência de se realizar previsão de receitas pela Lei de Responsabilidades Fiscal (LRF) por parte dos poderes federal, estadual e municipal, onde encontra-se determinado no seu artigo 12, a exigência da apresentação de relatório específicos com a previsão de receitas, bem como a descrição do método empregado para sua confecção. Entretanto, não é determinado um método para essa estimativa, sugere-se apenas o uso dos dados de arrecadação dos últimos três meses.

Como pode ser visto, a previsão constitui-se como uma importante ferramenta na tomada de decisão para os gestores públicos, podendo auxiliar no desenvolvimento de políticas públicas e no aumento do bem-estar econômico. Assim, o presente trabalho tem como propósito apresentar diferentes modelos de previsão para uma das principais rubricas da receita da Secretaria da Fazenda do estado do Ceará, a saber, ICMS, bem como seus métodos e técnicas econométricas para testar o poder de previsão dos modelos estudados.

As metodologias empregadas no presente trabalho consistem na aplicação de técnicas de análise de séries temporais, denominadas de: modelo auto-regressivo e de médias móveis (ARIMA), alisamento exponencial, função de transferência e combinação de previsões, onde se ressalta que a natureza das previsões neste estudo é de cunho essencialmente quantitativo baseadas em informações de períodos passados.

O estudo está dividido em quatro seções, contando com esta introdução, onde na segunda parte abordam-se as questões metodológicas dos modelos econométricos utilizados para efetuar previsões que, de maneira geral, expõem-se com base na bibliografia consultada, os aspectos teóricos dos modelos empregados nas previsões da série estudada.

A terceira seção trata da base de dados e dos resultados empíricos das previsões obtidas com base nas técnicas estudadas, bem como dos critérios utilizados para a seleção dos modelos capazes de gerar previsões. Além disso, após a escolha dos modelos de previsão mais adequados e do resultado de sua combinação, ilustram-se os resultados da previsão trimestral do ICMS para o ano de 2011. Por fim, na quarta etapa, apresentam-se as conclusões do trabalho.

2. REFERENCIAL TEÓRICO

Esta seção tem como objetivo relacionar alguns estudos realizados na área de previsão do ICMS e apresentar as principais metodologias de previsão que serão utilizadas no presente trabalho, bem como as medidas de eficiência das previsões realizadas.

2.1 Estudos na área de previsão do ICMS

A utilização de séries temporais para realizar previsão é bastante freqüente, sendo a literatura nessa área vasta e abrangente. Desta forma, nesta seção estão relacionados alguns trabalhos relevantes sobre o tema.

Castelar, Ferreira e Linhares (1996), apresenta um estudo sobre modelos de previsão para o ICMS do Estado do Ceará, através da combinação de três modelos de séries temporais: Alisamento Exponencial (ou de *Holt-Winters*), ARIMA (ou Metodologia de *Box-Jenkins*) para previsão de curto prazo (dados mensais), e Função de Transferência para previsão de curto prazo e longo prazo (anual). No estudo, constatou-se que a combinação de modelos, por utilizar diferentes informações, apresenta maior eficiência que modelos individuais. Na previsão de curto prazo, os testes apresentaram um Erro Percentual Absoluto Médio (EPAM) de 4,8%. Quando analisado o período anual, a magnitude do erro de predição para dois anos à frente foi de 9,2% e 12%.

Santos e Costa (2008) utiliza os métodos de alisamento exponencial sazonal de *Holt-Winters* aditivo e multiplicativo na previsão da arrecadação mensal do ICMS para o Estado do Maranhão de janeiro de 2003 a dezembro de 2008. Quando comparados os erros percentuais absolutos médios, a técnica de alisamento exponencial sazonal de *Holt-Winters* aditivo mostrou-se superior ao modelo de alisamento exponencial sazonal de *Holt-Winters* multiplicativo.

Por sua vez, Rocha Neto (2008) faz uso da abordagem temporal baseada na metodologia de *Box & Jenkins* (ARIMA), com o uso de um conjunto de processos estocásticos e emprego de *Dummies* Sazonais (DS), para realizar previsão da arrecadação mensal do ICMS do Estado do Ceará. No intuito de obter uma metodologia mais eficiente possível, ou seja, com menor margem de erro, comparando-a com o método de previsão utilizado pela Secretaria da Fazenda do Estado do Ceará – SEFAZ-CE. Analisando o período de janeiro de 2001 a agosto de 2007, concluiu que o modelo temporal de DS é o mais ajustado para se realizar previsões, pois permite suavizar o efeito sazonal.

Cruz (2007), ao fazer a previsão do ICMS para o estado do Piauí, utilizou os modelos ARMA, Função de Transferência, e por fim fez a combinação das previsões. O autor verificou que o método de função de transferência, a combinação de previsão e o modelo ARMA (2,3) apresentaram erro percentual absoluto médio de 4,4%, 4,5% e 6,2%, respectivamente, após a inclusão de uma variável qualitativa nas estimações dos modelos.

2.2 Métodos de previsão

A previsão é uma parte importante da análise econométrica, podendo a metodologia utilizada para se realizar previsão ser classificada quanto a sua natureza em qualitativa e quantitativa.

As previsões baseadas em métodos qualitativos são comumente utilizadas quando não está disponível uma base de dados históricos ou quando são esperadas mudanças significativas no ambiente em que se dá o processo estudado. Esse método baseia-se na opinião de especialistas, e é conhecido também como método de julgamento.

De acordo com Gujarati (2006), os métodos quantitativos de previsão baseiam-se na análise de séries históricas, pressupondo que os valores futuros das séries seguem os mesmos padrões de comportamento do passado, e que as mesmas estabelecem um padrão que possa ser modelado. Porém, esse método apresenta limitações quando os padrões de comportamento da série se alteram.

Os métodos quantitativos de previsão se classificam em métodos univariados e multivariados. Nos métodos univariados as características das séries de interesse são explicadas unicamente a partir do comportamento da própria série, portanto trata-se de uma análise de séries ordenadas no tempo. Nos métodos multivariados, as características das séries de interesse utilizam uma relação de interdependência e causalidade entre várias séries para estimar o comportamento futuro da série estudada.

Neste trabalho, abordam-se os modelos univariados: auto-regressivos integrados de médias móveis (ARIMA) e métodos de alisamento exponencial (*exponential smoothing*); e o modelo multivariado: função de transferência.

Com relação às séries temporais, vale ressaltar que se trata de um conjunto de variáveis aleatórias ordenadas no tempo que, dependendo da forma como forem observadas, podem ser classificadas em contínuas (a todo instante) ou discretas (em intervalos fixos de

tempo). Sendo que a grande parte dos dados econômicos é coletada em pontos discretos de tempo, e sua representação é dada por Y_t .

Um tipo de processo estocástico que recebe muita atenção dos analistas de séries temporais é o chamado *processo estocástico estacionário*, o que se deve ao fato de que na maioria dos trabalhos empíricos baseados em séries temporais, pressupõe-se que estas sejam estacionárias.

Um processo fundamental, puramente aleatório, das séries estacionárias estocásticas discretas é admitido como um processo de *ruído branco*, que apresenta média zero, variância constante e é serial não correlacionado.

2.3 Modelos ARIMA

O modelo ARIMA consiste na busca de um modelo auto-regressivo integrado de médias móveis que melhor se ajuste a um conjunto de dados e que descreva o processo estocástico gerador da série temporal, também conhecida como metodologia de *Box-Jenkins*. Segundo Castelar, Ferreira e Linhares (1996), para essa classe de modelos os elementos que explicam o comportamento das séries temporais econômicas residem nos seus valores passados, ou defasados, e dos termos de erro estocásticos.

Quando uma série estacionária é formada por um processo estocástico de características auto-regressivas e de médias móveis, temos um processo ARMA (p,q) , sendo representado por:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (1)$$

Onde:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t \quad (2)$$

representa o termo auto-regressivo, onde a variável aleatória depende de suas próprias observações passadas e de um termo aleatório; e

$$Y_t = \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (3)$$

representa o termo de médias móveis, que é uma combinação linear de termos de erro de um ruído branco.

Caso seja necessário diferenciar uma série temporal d vezes para torná-la estacionária e estão modelá-la pelo processo ARMA (p,q) , dizemos que a série temporal é ARIMA (p,d,q) , sendo uma série temporal auto-regressiva de médias móveis, onde p representa o número de termos auto-regressivos; d , o número de vezes que devemos diferenciar a séries para que ela se torne estacionária; e q , o número de termos de médias móveis.

A estratégia para construção e escolha de um modelo ARIMA adequado para gerar previsão consiste em três etapas:

i) Identificação do modelo:

Consiste em determinar os valores adequados de p , d e q , do modelo ARIMA (p,d,q) , onde, o primeiro passo consiste em verificar se a série é estacionária.

Pode-se dizer que uma série temporal é estacionária quando, independente das mudanças na origem no eixo do tempo, ela mantém suas médias e variâncias constantes. Segundo a literatura, pode-se classificar a estacionariedade em:

- Série estritamente estacionária:

$$E(Y_t) = \mu \quad (4)$$

$$\text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (5)$$

- Série fracamente estacionária ou estacionária de segunda ordem (GUJARATI, 2006):

$$E(Y_t) = \mu \quad (6)$$

$$\text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (7)$$

$$\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (8)$$

Uma forma de verificar a estacionariedade da série é através do *teste de raiz unitária de Dickey-Fuller Aumentado* (ADF), onde o teste consiste em estimar a seguinte regressão:

$$\Delta y_t = \mu + \alpha y_{t-1} + \sum_{i=1}^p \lambda_i \Delta y_{t-1} + \varepsilon_t \quad (9)$$

onde ε_t é um termo de erro de ruído branco puro e $\Delta y_{t-1} = (y_{t-1} - y_{t-2}), \Delta y_{t-2} = (y_{t-2} - y_{t-3})$ é a quantidade de termos de diferença defasados a serem incluídos, e é determinada empiricamente até que o termo de erro não apresente correlação serial. O teste tem como hipótese nula a presença de raiz unitária na série; caso o resultado seja positivo, diz-se que a série é estacionária.

Quando a série é não-estacionária, a mesma pode ser estacionarizada pela técnica das diferenças; ou quando o problema for de instabilidade na variância, a solução mais adotada consiste na transformação logarítmica dos dados.

De acordo com Bueno (2008), a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP) e os resultantes *correlogramas*², auxiliam na identificação da ordem dos processos AR(p), MA(q) ou ARMA(p,q). Os processos AR(p) e MA(q) apresentam padrões opostos de FAC e FACP, onde o processo AR(p) é caracterizado por uma FAC declinada geométrica ou exponencialmente e uma FACP com os primeiros “ p ” coeficientes de correlação significativamente diferentes de zero e os demais iguais a zero, e no processo MA(q) ocorre o posto. Como podemos observar, a FAC identifica a defasagem do MA, e a FACP identifica a defasagem do AR. No processo ARMA(p,q), ambas as funções decaem exponencialmente, onde a FAC começará a decair a partir da defasagem “ q ”, e a FACP a partir da defasagem “ p ”. Ainda segundo Bueno (2008), as condições apresentadas podem ser resumidas na seguinte tabela:

Tabela 1 – Padrões teóricos das funções de autocorrelação e autocorrelação parcial.

Modelos	FAC	FACP
AR(p)	Decai exponencialmente	Truncada na defasagem p
MA(q)	Corte na defasagem q	Decai exponencialmente
ARMA(p,q)	Decai exponencialmente se $j > q$	Decai exponencialmente se $j > p$

Fonte: Bueno (2008, p. 43).

Para Bueno (2008) o melhor modelo será o mais parcimonioso (isto é, com menor número de parâmetros), que deverá gerar menos imprecisão de estimativas justamente porque tem menos parâmetros.

² Representação das funções contra a duração da defasagem. (Gujarati, 2006)

A tarefa de identificar o modelo através da análise do correlograma pode ser complicada, pois vários modelos podem ser julgados como adequados às séries. Uma forma de encontrar o número ideal de parâmetros de um modelo seria a utilização dos chamados critérios de informação³, onde segundo a literatura os mais conhecidos são: o critério de informação de Schwarz (SIC) e de Akaike (AIC). De acordo com Bueno (2008) tem-se que:

- O critério de informação de Schwarz (SIC), ou Critério de Informação Bayesiano:

$$SIC(p, q) = \ln \hat{\sigma}^2 + n \frac{\ln T}{T} \quad (10)$$

onde, $n = p + q$, se o modelo não tem constante, e $n = p + q + 1$, se há constante no modelo, T é o número de observações, e a variância é dada por:

$$\hat{\sigma}^2 = \frac{\sum_{t=1}^T \hat{\varepsilon}_t^2}{T} \quad (11)$$

- E o critério de informação de Akaike (AIC):

$$AIC(p, q) = \ln \hat{\sigma}^2 + n \frac{2}{T} \quad (12)$$

Quanto mais parâmetros são estimados no mesmo período de amostra, menor será o erro estimado, mas isso será penalizado na segunda parcela da estatística (Bueno, 2008, p. 47). Por isso, deve-se escolher o modelo com os menores AIC e SIC.

Ainda segundo Bueno (2008), o critério de Schwarz é “assintoticamente consistente”, tendendo a escolher um modelo mais parcimonioso que o critério de Akaike (que tem melhor desempenho para pequenas amostras).

ii) estimação dos parâmetros

Após a identificação do modelo provisório $ARIMA(p, d, q)$ para a série temporal, o próximo estágio consiste na estimação dos modelos univariados estacionários usando o

³ A idéia do critério de informação é minimizar uma função baseada nos resíduos, penalizada pelo número de regressores. (Bueno, 2008)

método de máxima verossimilhança. Para isso, assume-se distribuição normal ou *t*-student e procura-se estimar o seguinte vetor de parâmetros:

$$\psi = (c, \alpha_1, \alpha_2, \dots, \alpha_p; \beta_1, \beta_2, \dots, \beta_q) \quad (13)$$

que maximiza a probabilidade de a amostra pertencer à distribuição especificada. De acordo com Bueno (2008), nessas condições, os estimadores de Máxima Verossimilhança serão aproximadamente estimadores de mínimos quadrados.

iii) diagnóstico de resíduos:

Depois de identificado e estimado um modelo ARMA (ou ARIMA), o último passo é diagnosticar sua adequação, o que consiste, geralmente, em examinar a série de resíduos gerada pelo modelo. Inicialmente, assumiu-se que os erros aleatórios são normalmente e independentemente distribuídos (*ruído branco*). Após a estimação, o mesmo deve acontecer com os resíduos estimados (BUENO, 2008).

De acordo com Bueno (2008) a primeira coisa a ser feita é examinar a FAC e a FACP dos resíduos estimados, como se fosse uma série temporal qualquer. Caso apresentem alguma estrutura identificável, a hipótese nula é rejeitada, o que implica em dizer que ainda existe alguma informação não captada pelo modelo.

Segundo Cruz (2007), outra forma de verificar o ajustamento do modelo à série é através da estatística Q de *Ljung-Box*⁴, que testa a significância conjunta das autocorrelações residuais, dada pela seguinte equação:

$$Q = N(N+2) \sum_{k=1}^K \frac{1}{N-k} r_k^2 \quad (14)$$

onde: *N* é o número de observações na série temporal; *k* é o número de defasagens checadas, e *r* representa a função de autocorrelação do *k*-ésimo termo residual.

A autocorrelação dos resíduos é obtida pela equação:

⁴ A estatística Q na defasagem *k* é um teste estatístico da hipótese nula de ausência de autocorrelação até a ordem *k* (SOARES; CASTELAR, 2003, p. 218)

$$\hat{r}_k = \frac{\sum_t \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_t \hat{\varepsilon}_t^2} \quad (15)$$

Quando o Q calculado for maior que o valor da distribuição qui-quadrado correspondente com $K-p-q$ graus de liberdade, rejeita-se a hipótese nula de *ruído branco*, ou seja, o modelo é considerado inadequado (CRUZ, 2007, p. 38). Neste caso, deve-se descartar o modelo e voltar aos estágios anteriores para testar outras possibilidades, até que se encontre um modelo cujos resíduos comportem-se como *ruído branco*.

Todos esses processos têm como finalidade a utilização do modelo identificado, estimado e testado para fazer previsão.

2.4 Modelos de alisamento exponencial

Os métodos de alisamento exponencial consistem em ponderar uma média móvel do valor atual observado com relação aos valores contidos nos instantes anteriores, fazendo com que esse valor diminua exponencialmente no tempo. Existem diversos métodos de alisamento exponencial, que são adotados de acordo com as características da série observada.

O modelo de alisamento exponencial simples (AES) é utilizado para séries temporais sem tendência e sem sazonalidade. Segundo Melo (2001), esse modelo tem como objetivo estimar a “média” presente na série e usá-la como previsão de valores futuros, com base na seguinte equação:

$$\bar{y}_t = \alpha y_t + (1 + \alpha) \bar{y}_{t-1} \quad (16)$$

onde y_t é a série alisada exponencialmente e α é um parâmetro conhecido como a constante de suavização, com valor estimado que varie entre 0 e 1. Nesse modelo o valor de α afeta exponencialmente os valores passados, pois minimiza a soma dos erros quadrados. Quanto mais perto de 1 estiver α , maior o peso atribuído ao valor corrente de y_t na geração de \bar{y}_t (PINDYCK; RUBINFELD, 2004, p. 553). Isso implica que valores menores de α geram uma série mais fortemente alisada.

Quando a série temporal apresenta tendência, o parâmetro apresentado acima, α , pode ser modificado para incorporar as variâncias médias na tendência de longo prazo que podem estar presentes na série. Esse modelo é chamado de *Modelo de Holt* que além do

parâmetro de alisamento α , incorporamos ao modelo um parâmetro que representa a tendência, β , onde ambos variem entre 0 e 1. Assim, quanto menor α e β , mais forte o alisamento.

$$\begin{aligned}\bar{y}_t &= \alpha y_t + (1 + \alpha)(\bar{y}_{t-1} + T_{t-1}) \\ T_t &= \beta(\bar{y}_t - \bar{y}_{t-1}) + (1 - \beta)T_{t-1}\end{aligned}\quad (17)$$

onde T_t representa o valor da tendência no tempo t , ou seja, a taxa média de aumento, na série estimada, sendo T_t incluído para impedir que a estimação de \bar{y}_t se desvie dos valores da série original y_t . Neste caso, verifica-se que o parâmetro β é, também, um coeficiente de alisamento.

De acordo com Melo (2001), caso a série temporal contenha movimentos sazonais de período L , o *Modelo de Holt* precisa ser alterado para incluir um componente sazonal, em adição ao coeficiente de alisamento e ao parâmetro de tendência. Sendo assim, o *Modelo de Holt-Winters* sazonal é definido de modo que para cada período seja necessário estimar um fator de sazonalidade, S_t . Onde a primeira variante do modelo é a sazonalidade aditiva, que supõe a sazonalidade constante ao longo da série que está sendo prevista:

$$\begin{aligned}\bar{y}_t &= \alpha(y_t - S_{t-L}) + (1 + \alpha)(\bar{y}_{t-1} + T_{t-1}) \\ T_t &= \beta(\bar{y}_t - \bar{y}_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma(y_t - \bar{y}_t) + (1 - \gamma)(S_{t-L})\end{aligned}\quad (18)$$

onde α , β e γ são os parâmetros de alisamento que variam entre 0 e 1.

Para a sazonalidade multiplicativa, que supõe a sazonalidade estar mudando ao longo da série, tem-se:

$$\begin{aligned}\bar{y}_t &= \alpha \left(\frac{y_t}{S_{t-L}} \right) + (1 + \alpha)(\bar{y}_{t-1} + T_{t-1}) \\ T_t &= \beta(\bar{y}_t - \bar{y}_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma \left(\frac{y_t}{\bar{y}_t} \right) + (1 - \gamma)(S_{t-L})\end{aligned}\quad (19)$$

Ao incorporar a sazonalidade no modelo, aumenta-se naturalmente a necessidade de incorporar mais dados.

Segundo Santos e Costa (2008), os algoritmos de *Holt-Winters* sazonal aditivo e multiplicativo podem fornecer previsões bem diferentes. Caso a série apresente oscilações sazonais aproximadamente constantes, o modelo aditivo é mais indicado. Porém, se as

oscilações sazonais forem proporcionais ao nível da série, o modelo multiplicativo é mais indicado. Sendo que, nos dois procedimentos os valores dos parâmetros de alisamento são estimados de forma a minimizar a soma dos erros de previsão um passo a frente ao quadrado.

2.5 Modelos de função de transferência

Os modelos apresentados até agora são conhecidos como modelos univariados, onde o comportamento de uma série no futuro é explicado pelos valores da própria série ao longo do tempo. No entanto, pode-se combinar os modelos de séries temporais univariados com a análise de regressão para produzir melhores previsões, em relação ao uso de apenas uma das técnicas. Essa combinação é conhecida como modelo de função de transferência ou modelo multivariado auto-regressivo de médias móveis (MARMA).

O objetivo principal desse modelo é permitir uma melhor previsão, pois inclui informações não contempladas na série estudada, a partir da inclusão de variáveis explicativas com a qual a mesma apresente uma relação de causalidade (CASTELAR; FERREIRA; LINHARES, 1996).

Para Pindyck e Rubinfeld (2004, p. 678), “um modelo de função de transferência relaciona uma variável dependente aos seus próprios valores defasados, aos valores correntes e defasados de uma ou mais variáveis explanatórias, e a um termo de erro parcialmente “explicado” por um modelo de série temporal”.

Desta forma, a função de transferência fica definida como:

$$Y_t = \alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n + \varepsilon_t \quad (20)$$

onde,

$$\varepsilon_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_p \varepsilon_{t-p} + \beta + \phi_1 v_{t-1} + \phi_2 v_{t-2} + \dots + \phi_q v_{t-q} + v_t \quad (21)$$

Para a estimação do modelo de função de transferência é necessário realizar duas etapas:

- i) Identificar a equação do modelo de regressão linear e estimá-la;
- ii) Ajustar um modelo ARIMA para a série de resíduos desta equação.

Em seguida, combinam-se os dois modelos obtidos nas etapas anteriores para identificar um modelo dinâmico para as séries originais.

2.6 Combinação de previsões

A técnica de combinação de previsões consiste em reunir diferentes informações contidas nos métodos de previsão individuais com o objetivo de aumentar o desempenho da estimação. Conforme resultados obtidos em outros estudos na área, a utilização dessa técnica costuma apresentar melhor resultado do que as previsões individuais. Além disso, a diversificação dos modelos ajuda a diminuir as deficiências contidas nos modelos individuais.

Segundo Winkler e Makridakis (1983), utilizar a média das previsões apresenta melhores resultados que uma técnica de previsão pobre, pois os resultados registrados pelos autores sugerem que o uso de média das previsões traz consideráveis benefícios práticos em termos de melhoria de acurácia da previsão e de diminuição da variância dos erros.

Após a estimação dos modelos de previsão individual, seleciona-se a melhor forma de combinar os mesmos, o que pode ser feito através do cálculo da média aritmética ou ponderada das previsões, ou mesmo com a escolha de pesos adaptativos baseados no desempenho dos modelos, onde o peso está relacionado com o seu grau de precisão e correlação entre os desvios das demais séries.

Segundo Castelar, Ferreira e Linhares (1996), o ponto crucial na determinação desses pesos é a manutenção de uma relação lógica entre magnitude do coeficiente de ponderação e desempenho do modelo na previsão.

Segundo Gupta e Wilton (1977), que propuseram a utilização de uma técnica de combinação simples em função das dificuldades de estimação dos pesos ótimos para a combinação de previsão, este estudo se concentra nos seguintes métodos de combinação linear:

i) Modelo de média simples:

Consiste na combinação linear sem constante e sem restrições nos pesos, onde os mesmos são estimados por Mínimos Quadrados Ordinários:

$$C_k = \left(\frac{F_1 + F_2 + \dots + F_n}{n} \right) \quad (22)$$

onde, C_k é a previsão combinada para os “ k ” períodos, F_n é a previsão do n -ésimo método para a variável “ F ” e n é o número de previsões incluídas na combinação.

ii) Modelo de pesos diferentes com restrições:

Consiste em uma combinação linear sem constante e com restrições nos pesos, que somam um.

$$C_k = w_1 F_1 + w_2 F_2 + \dots + w_n F_n \quad (23)$$

onde, w_n são os pesos e $w_1 + w_2 + \dots + w_n = 1$.

iii) Modelo de pesos diferentes com constante:

É uma combinação linear sem restrição nos parâmetros (pesos), porém com a adição de uma constante.

$$C_k = w_1 F_1 + w_2 F_2 + \dots + w_n F_n + c \quad (24)$$

onde, c é uma constante diferente de zero.

Ainda segundo Castelar, Ferreira e Linhares (1996), os procedimentos que se destacam para estimação dos pesos de uma determinada combinação linear são:

$$w_i = \frac{\left(\sum_{s=t-v}^{t-1} e_s^{(i)2} \right)^{-1}}{\sum_{j=1}^p \left(\sum_{s=t-v}^{t-1} e_s^{(j)2} \right)^{-1}} \quad (25)$$

onde: $i = (1, \dots, p)$ e v é o número de períodos inclusos no processo de determinação dos pesos;

$$w_i = \beta w_{i,t-1} + (1 - \beta) \left[\frac{\left(\sum_{s=t-v}^{t-1} e_s^{(i)2} \right)^{-1}}{\sum_{j=1}^p \left(\sum_{s=t-v}^{t-1} e_s^{(j)2} \right)^{-1}} \right] \quad (26)$$

onde, β é uma constante no intervalo $[0,1]$; e $w_{i,t-1}$ é peso distribuído ao método de previsão “ i ”, baseado nos dados do período “ $t-1$ ”.

2.7 Medidas de eficiência de previsões

Ao se considerar a predição como objetivo do modelo, deve-se priorizar a preocupação com o ajustamento da previsão *ex-post* com os valores disponíveis, mais do que

o ajustamento estatístico (CASTELAR; FERREIRA; LINHARES, 1996). Uma forma para observar o ajustamento do modelo é comparar os valores previstos com os valores observados da série.

Mas, segundo a literatura, existem vários métodos de medição da adequação para avaliação da previsão *ex-post*, que utilizam comumente os erros de previsão nos seu cálculo. Dentre os métodos mais utilizados estão:

- i) O Erro Médio Absoluto (EMA), que é definido como a média dos valores absolutos de cada resíduo e é representado por:

$$EMA = \frac{\sum_{i=1}^n |Y_t - \bar{Y}_t|}{n} \quad (27)$$

onde Y_t é o valor observado e \bar{Y}_t é o valor estimado e n é o número de valores previstos obtidos dos dados passados.

- ii) A Raiz do Erro Quadrático Médio (REQM) é a raiz quadrada da média dos valores quadráticos dos erros, sendo:

$$REQM = \sqrt{\frac{\sum_{i=1}^{n+h} (\bar{Y}_t - Y_t)^2}{h+1}} \quad (28)$$

- iii) O Erro Percentual Absoluto Médio (EPAM) leva em consideração o erro relativo de cada previsão e é representado por:

$$EPAM = \frac{\frac{\sum_{i=1}^n |Y_t - \bar{Y}_t|}{Y_t}}{n} \quad (29)$$

- iv) O Coeficiente de Desigualdade de Theil está limitado ao intervalo [0,1], em que 0 indica um perfeito ajustamento e é representado por:

$$TIC = \frac{\sqrt{\frac{1}{n+1} \sum_{t=h}^{h+n} (\bar{Y}_t - Y_t)^2}}{\sqrt{\frac{1}{n+1} \sum_{t=h}^{h+n} \bar{Y}_t^2} \sqrt{\frac{1}{n+1} \sum_{t=h}^{h+n} Y_t^2}} \quad (30)$$

Não existe um consenso sobre qual método é mais indicado. Nessa pesquisa optou-se por utilizar o EPAM na combinação de previsões, por ter a vantagem de indicar a magnitude individual do erro de cada previsão, por utilizar a razão entre os valores previstos e os valores reais.

3. RESULTADOS EMPÍRICOS

Esta seção inicia-se com uma descrição da base de dados e tem como objetivo apresentar os principais resultados da aplicação das metodologias de previsão, descritas anteriormente.

3.1 Base de dados

Para realizar a análise de previsão da arrecadação trimestral do ICMS para o ano de 2010, através das metodologias descritas acima, será utilizada uma série de dados sobre a arrecadação do imposto nos municípios da Mesorregião Noroeste do Estado do Ceará. Salienta-se que os modelos estimados foram controlados para Sobral, ou seja, não inclui o município de Sobral na amostra, pois após alguns testes se verificou que a inclusão do mesmo poderia viesar os resultados dos parâmetros estimados, o que pode ser explicado porque o município possui uma das maiores arrecadações de ICMS do estado⁵.

Os dados referentes ao ICMS foram fornecidos pela Secretaria da Fazenda do Estado do Ceará, estando a série, compreendida de janeiro de 2001 a dezembro de 2010, perfazendo 40 observações trimestrais, deflacionadas pelo Índice Geral de Preços – Disponibilidade Interna (IGP-DI) divulgado pela Fundação Getúlio Vargas – tendo como base 100 o mês de agosto de 1994⁶. Assim, os dados serão expressos em reais de agosto de 1994 e podem ser interpretados como preços constantes.

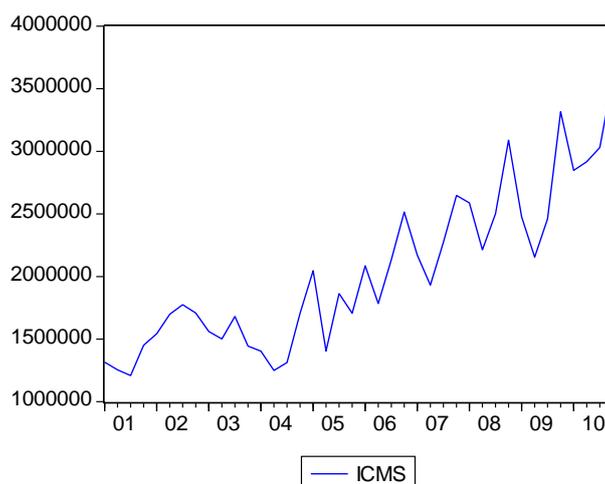


Gráfico 2 – Série Temporal do ICMS Regional – valores reais.

Fonte: elaborado pela autora a partir do software Eviews.

⁵ Essa discrepância da arrecadação do ICMS de Sobral pode ser gerada por conta dos créditos recebidos pelo município do Fundo de Desenvolvimento Industrial que está contabilizado no “ICMS Industrial do Município”.

⁶ A série histórica do IGP-DI foi obtida no IPEADATA.

Cabe ressaltar que os valores da arrecadação trimestral do ICMS do último trimestre (janeiro de 2011 a março de 2011) já estão disponíveis, e foram reservados para a realização da previsão *ex-post* e para comparação com os valores previstos.

A série do ICMS apresenta uma média amostral de 2,039 bilhões de reais com um desvio padrão de 0,6232 bilhões de reais, tendo como valor máximo 3,590 bilhões de reais e como valor mínimo 1,209 bilhões.

A distribuição de frequência do ICMS está representada no histograma da série (Figura 1), com coeficiente de curtose de 2,5581.

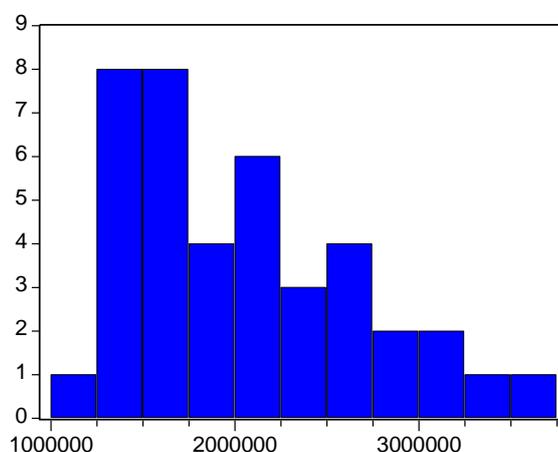


Figura 1 – Histograma da série.

Fonte: elaborado pela autora a partir do software Eviews.

3.2 Teste de Raiz Unitária

Antes de utilizar a variável em uma regressão é fundamental testar sua estacionariedade, que é condição necessária para formulação dos modelos auto-regressivos.

A escolha do número máximo de defasagens da série (k) é feita com apoio em uma função fixa do tamanho da amostra. Nesse trabalho, utilizou-se a metodologia desenvolvida por Schwert (1989)⁷, $K = \text{int}\{c(T/100)^{1/d}\}$, onde k é o número (inteiro) de defasagens, T é o tamanho da amostra, e c e d são constantes. Os valores de c e d são definidos por análise de experimentos de Monte Carlo, onde c e d são iguais a 4. Como a amostra é composta de 40 observações o número de defasagens máximo é igual a 3. Portanto, $K \in [0;3]$.

⁷ Schwert (1989), Tests for Unit Roots: A Monte Carlo Investigation.

Após definir o K máximo, $K = 3$, adotou-se o Critério de Informação de Akaike (AIC) para definir o número de defasagens utilizado no teste de raiz unitária, onde fez-se uso do procedimento conhecido como do geral para o específico.

De acordo com o teste ADF utilizou-se neste trabalho apenas a constante na estimação do teste, pois nos testes usando constante e tendência o coeficiente da variável se mostrou estatisticamente insignificante de acordo com a estatística t . Logo é desnecessário incluir a tendência no teste.

Tabela 2 – Teste de Raiz Unitária (ADF)

Séries*	Valor Crítico 5%	Número de defasagens**	Estatística do teste	Conclusão
ICMS	-2,9458	3	0,9786	Não rejeita
Δ ICMS	-2,9484	3	-3,4746	Rejeita

Fonte: Resultados da pesquisa obtidos a partir do software Eviews.

(*) foram incluídas nas equações de testes somente as constantes;

(**) foi utilizado o número de defasagens que minimizou o critério de AIC.

De acordo com a Tabela 2 que apresenta o resultado do teste ADF para série do ICMS utilizada nesse estudo, verifica-se que a hipótese nula de raiz unitária não pode ser rejeitada ao nível de 5% de significância, porém, rejeita-se a hipótese nula em primeira diferença. Portanto, a variável é integrada de ordem 1, ou seja, $I(1)$.

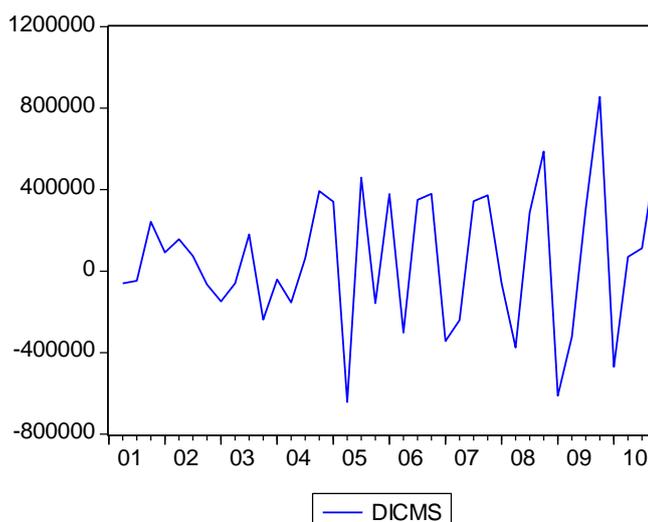


Gráfico 3 – Série Temporal do ICMS estacionaria.

Fonte: elaborado pela autora a partir do software Eviews.

3.3 ARIMA

Nessa seção apresentam-se os resultados dos modelos temporais estimados para realizar a previsão de arrecadação do ICMS trimestral para a Mesorregião Noroeste Cearense, com base na metodologia de *Box-Jenkins*, que conforme resultado obtido no teste ADF da série, identifica-se como modelo a ser estimado o $ARIMA(p, 1, q)$, restando então identificar a ordem p e q da série. A determinação de p e q deve ser feita de forma a obter o melhor ajuste possível do modelo.

Para identificação dos modelos utilizou-se, inicialmente, as Funções de Autocorrelação (FAC) e de Autocorrelação Parcial (FACP) para a série em primeira diferença do ICMS. Onde se verifica, com base na tabela 2, que a FAC é significativamente diferente de zero nas defasagens 2 e 4, e a FACP nas defasagens 2 e 3.

Tabela 3 – Correlograma da série temporal do ICMS estacionária.

Teste de Autocorrelação							
Defasagem	1	2	3	4	8	12	16
FAC	-0,229	-0,363	-0,094	0,378	0,152	0,042	-0,013
FACP	-0,229	-0,438	-0,409	0,046	-0,002	-0,073	0,077
Q	2,1972	7,8919	8,2850	14,827	18,100	19,261	19,524
Prob	0,138	0,019	0,040	0,005	0,020	0,082	0,242

Fonte: Elaborado pelo autor com base no correlograma da equação estimada a partir do software EViews.

Conforme identificação da tabela 3 do correlograma da série estimou-se alguns modelos na tentativa de identificar a série original e verificar seus respectivos Coeficientes de Akaike e Schwarz, na tabela 4. Observa-se que o melhor critério a ser utilizado nesse caso é o AIC, pois funciona de forma mais eficiente em pequenas amostras.

Tabela 4 – Equação estimadas para modelar a série temporal do ICMS e Critérios de Akaike e Schwarz do ARIMA.

Equações	Modelo	AIC	SIC
1	AR(2) AR(4) MA(2) MA(3)	27,9930	28,2152
2	AR(2) MA(2) MA(3)	27,9232	28,0973
3	AR(2) MA(3)	28,0500	28,1807
4	AR(2) AR(4) MA(2)	27,9682	28,1459
5	AR(2) MA(2)	27,9376	28,0682
6	AR(2) AR(4) MA(3)	28,1112	28,2890
7	AR(4) MA(2) MA(3)	28,1623	28,3400
8	AR(4) MA(2)	28,1105	28,2439
9	AR(1) AR(2) MA(3)	27,8512	28,0253
10	AR(2) MA(1) MA(2)	28,0100	28,1841

11	AR(2) MA(1) MA(3)	28,0161	28,1902
12	AR(2) MA(1) MA(2) MA(3)	27,7688	27,9865

Fonte: elaboração da autora.

De acordo com a tabela 4, o modelo que se mostrou mais adequado de acordo com a estatística de Akaike (AIC) é o que tem um termo auto-regressivo de primeira ordem no 2º trimestre e três termos em médias móveis no 1º, 2º e 3º trimestres e integrado de ordem 1.

Mas, nem sempre o modelo mais adequado para a estimação é o que apresenta o melhor desempenho para a previsão. A qualidade de previsão deve ser testada por meio de uma previsão *ex-post*, utilizando dados já observados para comparar os resultados estimados com os valores que efetivamente ocorreram e, desta forma, confrontar os diversos modelos estimados na tarefa de projeção.

Tabela 5 – Comparação da eficiência dos modelos na previsão *ex-post*

Equações	EMA	EPMA	REQM	Coefficiente de Theil
1	192031,8	9,5620	251373,5	0,0567
2	206738,4	10,8380	251337,7	0,0575
3	202662,0	10,5536	275131,9	0,0627
4	203374,8	10,1335	255471,1	0,0575
5	204596,9	10,3009	260093,1	0,0596
6	215982,2	10,9795	274412,2	0,0619
7	220146,0	11,0456	281507,4	0,0635
8	222116,5	11,1181	282268,8	0,0637
9	190831,2	10,0201	242449,0	0,0553
10	226532,7	11,4940	262482,0	0,0603
11	205744,2	10,7427	263281,4	0,0602
12	190236,3	9,91685	226462,4	0,0521

Fonte: elaboração da autora.

Conforme a tabela 5, pode-se observar que o modelo que apresenta melhor resultado para realização da previsão *ex-post* de acordo com a estatística do EMA, do REQM, do Coeficiente de Desigualdade de Theil e o segundo melhor de acordo com o EPAM é o ARIMA(1,1,3), pois quanto menores os valores das estatísticas melhor a qualidade da previsão.

Tabela 6 – Correlograma dos resíduos do ARIMA(1,1,3).

Teste de Autocorrelação							
Defasagem	1	2	3	4	8	12	16
FAC	0,294	0,174	0,125	0,050	-0,027	0,035	0,047

<i>FACP</i>	0,294	0,096	0,056	-0,015	-0,032	0,001	0,056
<i>Q</i>	3,4733	4,7255	5,3927	5,5012	5,5012	5,9469	6,7459
<i>Prob</i>	0,062	0,094	0,145	0,240	0,695	0,919	0,978

Fonte: Elaborado pelo autor com base no correlograma dos resíduos da equação estimada a partir do software EViews.

Com base na tabela 6, elaborada a partir do correlograma dos resíduos gerados pelo modelo estimado, verificou-se que os erros do modelo ARIMA(1,1,3) apresentaram comportamento de *ruído branco*, onde não é possível melhorar o modelo e que este pode ser utilizado para gerar previsão.

Após a identificação do modelo, estimação dos parâmetros e diagnóstico dos resíduos, obteve-se a seguinte estimativa:

$$\Delta \text{ICMS} = 46256,7882 - 1,0733 \text{ICMS}_{t-2} - 0,5653 \varepsilon_{t-1} + 0,9379 \varepsilon_{t-2} - 0,5240 \varepsilon_{t-3}$$

$$ep = (16312,25) \quad (0,0468) \quad (0,1599) \quad (0,0879) \quad (0,1554)$$

$$t = (2,8357) \quad (-22,9045) \quad (-3,5345) \quad (10,6646) \quad (-3,3719)$$

$$R^2 = 0,5112 \quad d = 1,9898$$

Conforme se observa na estimativa da equação, com base na estatística *t*, os coeficientes da equação são todos estatisticamente diferentes de zero, ou seja, significantes ao nível de 5%.

De acordo com as estimações, o Gráfico 3 apresenta o ajustamento dos valores estimados com os valores reais do ICMS para o período de janeiro de 2010 a dezembro de 2010.

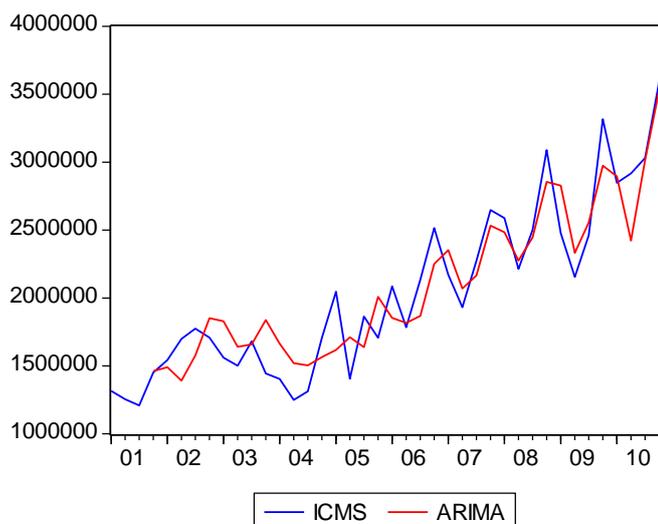


Gráfico 4 – Valores realizados e estimados pelo ARIMA(1,1,3) – período de janeiro de 2010 a dezembro de 2010.

Fonte: Elaborado pela autora com o auxílio do software EViews.

3.4 Alisamento Exponencial

Agora, apresentam-se os principais resultados de estimação dos modelos de alisamento exponencial (*Holt-Winters* Aditivo e Multiplicativo) e de previsão trimestral do ICMS dos municípios da Mesorregião Noroeste do Estado do Ceará para o primeiro trimestre de 2011.

No método de alisamento exponencial, não é necessário aplicar nenhuma estratégia de modelagem, pois o procedimento de previsão é considerado automático. Sendo assim, o algoritmo de *Holt-Winters* sazonal aditivo e multiplicativo foram obtidos por meio do programa E-Views.

Na tabela 7, pode-se observar os valores estimados através do alisamento exponencial sazonal aditivo e multiplicativo, bem como seus respectivos EPAM, que será usado como critério de seleção para escolha do modelo mais adequado para nossa série.

Tabela 7 – Comparação dos EPAM para a escolha do modelo de alisamento exponencial.

Período	ICMS	AEA	AEM	EPAM-A	EPAM-M
1º Trimestre/10	2847358,62	2935192,64	2891368,09	3,08	1,55
2º Trimestre/10	2917104,15	2593065,87	2682325,84	11,11	8,05
3º Trimestre/10	3029875,36	3004579,86	2982266,98	0,83	1,57
4º Trimestre/10	3590469,80	3366247,21	3292928,57	6,24	8,29
MÉDIA				5,32	4,86

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Nota: *AEA* – Estimação do ICMS com o modelo de Alisamento Exponencial Aditivo.

AEM – Estimação do ICMS com o modelo de Alisamento Exponencial Multiplicativo.

EPAM-A – Erro Percentual Absoluto Médio do Alisamento Exponencial Aditivo.

EPAM-M – Erro Percentual Absoluto Médio do Alisamento Exponencial Multiplicativo.

De acordo com a tabela 7, o modelo que apresenta melhor desempenho é o modelo sazonal multiplicativo de *Holt-Winters* com menor média do EPAM (4,86%).

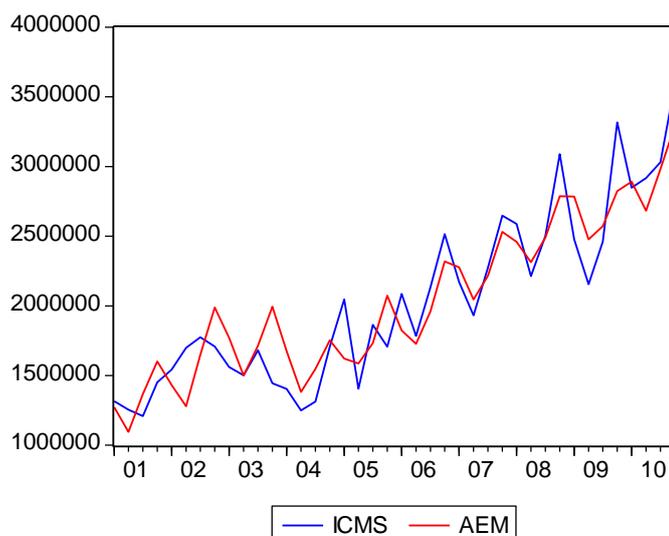


Gráfico 5 – Valores realizados e estimados pelo alisamento exponencial multiplicativo – período de janeiro de 2001 a dezembro de 2010.

Fonte: Elaborado pela autora com o auxílio do software Eviews.

3.5 Função de transferência

Na estimação da função de transferência, a variável Fundo de Participação Municipal (FPM) foi utilizada como variável explicativa, pois após estimativas iniciais, apresentou um movimento correlacionado com a arrecadação do ICMS. O que pode ser justificado pelo fato do FPM, influenciar o nível da atividade econômica dos municípios, por se tratar de uma injeção de recursos que dinamiza os negócios e, conseqüentemente, aumenta a arrecadação.

Para corroborar a inclusão do FPM como variável explicativa, foi calculado o coeficiente de correlação das variáveis, cujo valor foi de 0,8029, e podemos observar esse movimento no gráfico 5, a seguir:

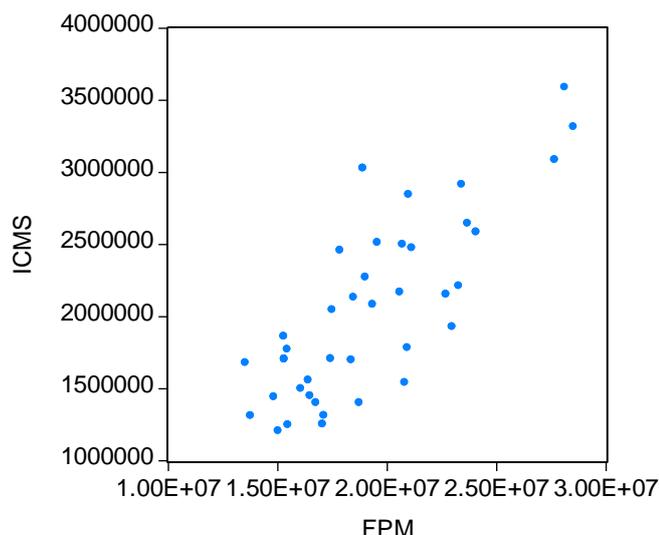


Gráfico 6 – Correlação ICMS x FPM – período de Janeiro de 2001 a Dezembro de 2010.

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Inicialmente, estimou-se a função de transferência contemplando as variáveis ICMS e FPM, com defasagens variando de 1 a 3, onde apresentou melhor resultado, em termos de adequação, o ICMS com três defasagens e o FPM em nível. A tabela 8 a seguir apresenta os modelos estimados bem como os resultados dos respectivos AIC e SIC.

Tabela 8 – Critérios de Akaike e Schwarz para os modelos de Função de Transferência.

Equações	Modelos	AIC	SIC
1	ICMS (-1) FPM	28,1329	28,2609
2	ICMS (-1) FPM (-2)	28,2774	28,4067
3	ICMS (-1) FPM (-3)	28,3079	28,4385
4	ICMS (-2) FPM	28,2945	28,4238
5	ICMS (-2) FPM (-3)	28,5453	28,6759
6	ICMS (-3) FPM	27,9772	28,1079

Fonte: elaboração da autora.

Nota: As equações omitidas na tabela não se apresentaram estatisticamente significantes.

O resultado da estimação desta função pode ser visualizado na equação a seguir:

$$\text{ICMS} = - 544561,99 + 0,5400\text{ICMS}_{t-3} + 0,0821\text{FPM}$$

$$ep = (238119,5) \quad (0,1013) \quad (0,0141)$$

$$t = (-2,2869) \quad (5,3286) \quad (5,8241)$$

$$R^2 = 0,7907 \quad d = 1,8385$$

Com base nas estatísticas t abaixo das variáveis, observa-se que os coeficientes da função de transferência são todos estatisticamente significantes.

No Gráfico 6 apresenta-se o ajustamento da estimação em relação à série original.

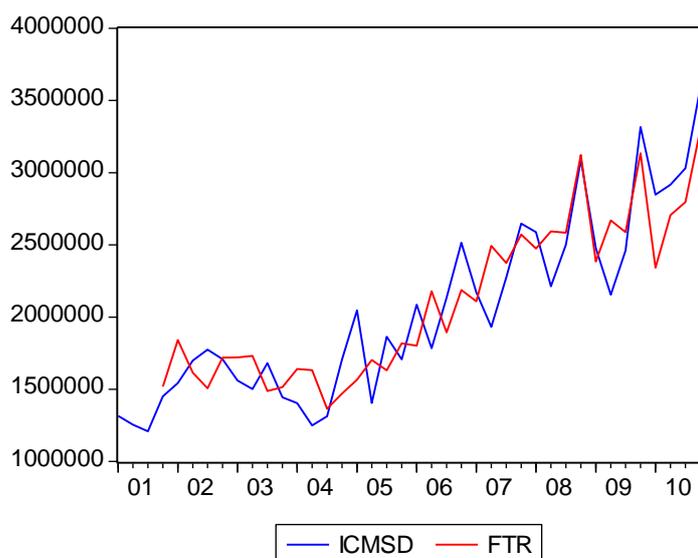


Gráfico 7 – Valores realizados e estimados com base na função de transferência – período de janeiro de 2001 a dezembro de 2010.

Fonte: Elaborado pela autora com o auxílio do software Eviews.

3.6 Previsões

Com base nos modelos estimados, realizaram-se previsões *ex-post* para o primeiro trimestre de 2011 (janeiro a março de 2011), o valor do ICMS realizado no período, bem como os valores estimados e seus respectivos EPAM, são apresentados na tabela 9, a seguir:

Tabela 9 – Valor realizado, valores previstos e EPAM do ICMS regional.

Modelo	ICMS	EPAM
ICMS	3025932,81	-
ARIMA	3288148,36	9,9168
AEM	3353927,38	10,8395
FTR	3098728,55	9,8788

Fonte: resultados obtidos pela autora com o auxílio do software Eviews.

Com base no EPMA, pode-se observar que o modelo que apresentou melhor desempenho na previsão foi a Função de Transferência, com erro de 9,87%, seguido pelo modelo ARIMA (9,92%) e Alisamento Exponencial Multiplicativo (10,84%).

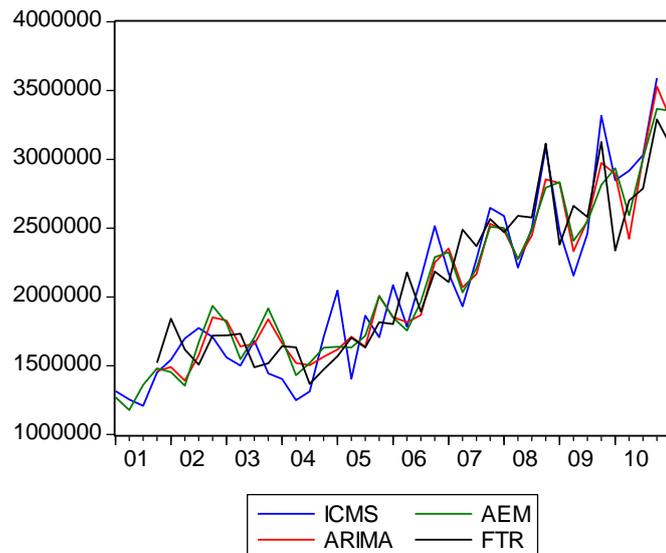


Gráfico 8 – Valores realizados e estimados com os modelos ARIMA(1,1,3), Alisamento exponencial Multiplicativo e Função de Transferência – período de janeiro de 2001 a março de 2011.

Fonte: Elaborado pela autora com o auxílio do software Eviews.

3.7 Combinação de previsões

Na tentativa de melhorar a previsão e tentar captar as informações contidas nos modelos individuais, optou-se por utilizar a técnica de combinação de previsões, com base na metodologia descrita anteriormente.

De acordo com os EPMA optou-se por determinar pesos, de forma aleatória, para combinar as previsões dos modelos Função de Transferência, ARIMA e Alisamento Exponencial Multiplicativo, onde se resultou na seguinte equação:

$$ICMS_{t+1}^{comb} = 0,18AEM + 0,30ARIMA + 0,52FTR$$

E com base na equação acima, realizou-se uma nova previsão utilizando a combinação de previsões.

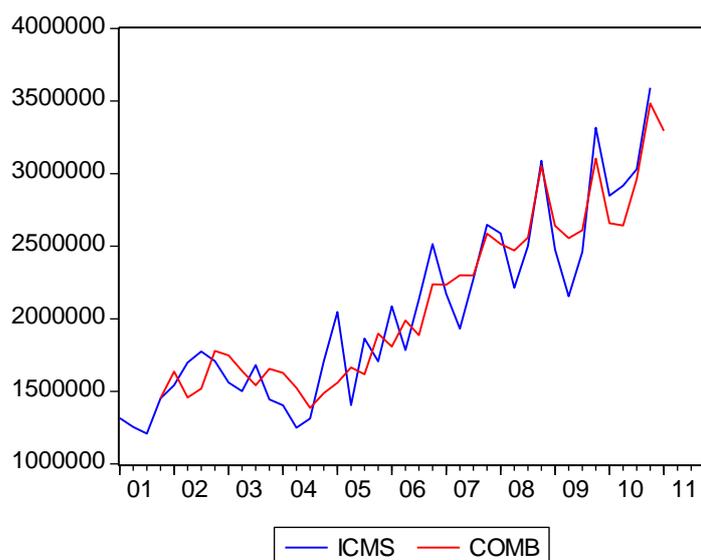


Gráfico 9 – Valores realizados e estimados com base na combinação de previsões – período de janeiro de 2001 a março de 2011.

Fonte: Elaborado pela autora com o auxílio do software Eviews.

O resultado das previsões de todos os modelos propostos por esse estudo será apresentado na tabela 10 abaixo:

Tabela 10 – Valores realizado e previstos do ICMS regional trimestral.

Modelo	ICMS	EPMA
ICMS	3025932,81	-
ARIMA	3288148,36	9,9168
AEM	3353927,38	10,8395
FTR	3098728,55	9,8788
COMB	3294436,53	9,6079

Fonte: elaboração da autora com base nos resultados.

Após as estimações verificou-se que a combinação de previsões apresenta o menor EPAM (9,61%), possivelmente por conter informações omitidas nos modelos individuais, sendo seguido pelo modelo Função de Transferência (EPAM de 9,88%), ARIMA (EPAM de 9,92%) e pelo alisamento exponencial multiplicativo (EPAM de 10,84%).

4. CONCLUSÃO

Este trabalho teve como objetivo apresentar modelos de previsão para o imposto sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual, intermunicipal e de comunicação (ICMS) para o ano de 2011 dos municípios que compõem a Mesorregião Noroeste do Estado do Ceará, dada sua importância para a atividade econômica municipal, regional e estadual do Ceará, sendo o comportamento de sua arrecadação motivo de preocupação para os gestores públicos.

Na busca do objetivo deste trabalho aplicaram-se métodos estatísticos e econométricos de previsões, sendo o estudo baseado nas técnicas de análise de séries temporais mais utilizadas na área. A saber: o modelo ARIMA, Alisamento Exponencial, Função de Transferência e a Combinação de Previsões.

Cabe ressaltar que as previsões efetuadas no estudo foram obtidas a partir de valores já realizados, portanto *ex post*, e que o mesmo desempenho dos modelos pode não ser observado para previsões fora da amostra.

Com base nas estimações das técnicas de análise de séries temporais utilizadas verificou-se que, para a amostra estudada, o modelo que apresentou melhor resultado na estimação da previsão foi o modelo de combinação de previsões (EPAM de 9,61%), seguido do modelo de Função de transferência (EPAM de 9,88%), do ARIMA (EPAM de 9,92%) e do modelo de alisamento exponencial multiplicativo (EPAM de 10,84%).

Esse resultado já era esperado, pois de acordo com a literatura, a técnica de combinação de previsões mostra-se mais precisa quando comparada com outras técnicas de previsão, por apresentar erros de previsão menores.

Uma possível extensão para trabalhos futuros seria estudar a inclusão de variáveis qualitativas nas estimações dos modelos, com o objetivo de captar mudanças na estrutura da série do ICMS estadual, que possam ter sido geradas a partir de medidas adotadas pela Secretaria da Fazenda do Estado do Ceará (SEFAZ-CE) para aumentar a arrecadação do imposto.

Outra possibilidade seria incluir mais variáveis explicativas no modelo função de transferência, tais como PIB dos municípios em estudo, o consumo de energia elétrica, entre outros, para melhorar a acurácia do modelo.

REFERÊNCIAS

- BRASIL. Constituição Federal. Brasília, 1988.
- _____. Lei Complementar n. 87 - 13 set. 1996. Brasília, 1996.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 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.
- CEARÁ. Lei Nº 12.612, de 07 de agosto de 1996.
- _____. Lei Nº 14.023, de 17 de dezembro de 2007.
- _____. Decreto Nº 29.306 de 05 de junho de 2008.
- CRUZ, C. C. S. **Análise de séries temporais para a previsão mensal do ICMS: o caso do Piauí**. Universidade Federal do Ceará, Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Economia - CAEN, Fortaleza, 2007.
- GUJARATI, D. N. **Econometria básica**. Rio de Janeiro: Elsevier, 2006.
- GUPTA, S.; WILTON, P. C. **Combination of Forecasts: An Extension**. Management Science, v. 13, n. 3, p. 356-372, 1977.
- HOLANDA, M.; BARBOSA, M.; COSTA, L.; NOGUEIRA, C. **Proposta de mudança no rateio da cota-parte do ICMS entre os municípios cearenses**. Fortaleza: IPECE, 2007. (Texto para Discussão, 51).
- MELO, B. S. V. **Modelo de previsão para a arrecadação tributária**. VI Prêmio Tesouro Nacional. Brasília, 2001.
- PINDYCK, R. S.; RUBINFELD, D. L. **Econometria – Modelos e Previsões**. 4 ed. Rio de Janeiro: Campus, 2004.
- ROCHA NETO, A. **Previsão para o ICMS do Ceará: comparação do desempenho da metodologia da SEFAZ-CE com o modelo ARIMA**. Universidade Federal do Ceará, Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Economia – CAEN. Fortaleza, 2008.
- SANTOS, A. V.; COSTA, J. H. F. **Análise de modelos de séries temporais para a previsão mensal do ICMS do Estado do Maranhão**. Cadernos IMESC 6. São Luís: IMESC, 2008.
- SCHWERT, G. W. **Tests for unit roots: A Monte Carlo investigation**. Journal of Business & Economic Statistics, v. 7, n. 2, p. 147-159, 1989.
- SOARES, I. G.; CASTELAR, I. **Econometria aplicada com o uso do Eviews**. Fortaleza: UFC/CAEN, 2003.

WINKLER, R. L.; MAKRIDAKIS, S. **The combination of forecast.** Journal of the Royal Statistical Society A., p. 2-146, 1983.

APÊNDICES

Apêndice A – Teste ADF da série ICMS em nível: de janeiro de 2001 a dezembro de 2010.

Null Hypothesis: ICMS has a unit root

Exogenous: Constant

Lag Length: 3 (Automatic based on AIC, MAXLAG=3)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.978649	0.9955
Test critical values: 1% level	-3.626784	
5% level	-2.945842	
10% level	-2.611531	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(ICMS)

Method: Least Squares

Sample (adjusted): 2002Q1 2010Q4

Included observations: 36 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ICMS(-1)	0.089735	0.091692	0.978649	0.3353
D(ICMS(-1))	-0.705089	0.173268	-4.069349	0.0003
D(ICMS(-2))	-0.736337	0.156871	-4.693914	0.0001
D(ICMS(-3))	-0.603365	0.158946	-3.796040	0.0006
C	-30205.25	187190.9	-0.161361	0.8729
R-squared	0.490797	Mean dependent var		59424.25
Adjusted R-squared	0.425093	S.D. dependent var		351935.7
S.E. of regression	266846.8	Akaike info criterion		27.95498
Sum squared resid	2.21E+12	Schwarz criterion		28.17492
Log likelihood	-498.1897	F-statistic		7.469866
Durbin-Watson stat	1.770873	Prob(F-statistic)		0.000246

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice B – Teste ADF da série ICMS em primeira diferença: de janeiro de 2001 a dezembro de 2010.

Null Hypothesis: D(ICMS) has a unit root

Exogenous: Constant

Lag Length: 3 (Automatic based on AIC, MAXLAG=3)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.474621	0.0148
Test critical values: 1% level	-3.632900	
5% level	-2.948404	
10% level	-2.612874	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(ICMS,2)

Method: Least Squares

Sample (adjusted): 2002Q2 2010Q4

Included observations: 35 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(ICMS(-1))	-2.164555	0.622961	-3.474621	0.0016
D(ICMS(-1),2)	0.660754	0.488883	1.351560	0.1866
D(ICMS(-2),2)	0.149918	0.335239	0.447198	0.6579
D(ICMS(-3),2)	-0.262276	0.186501	-1.406296	0.1699
C	109911.6	54501.28	2.016680	0.0528
R-squared	0.794071	Mean dependent var		13394.84
Adjusted R-squared	0.766614	S.D. dependent var		552067.2
S.E. of regression	266703.7	Akaike info criterion		27.95723
Sum squared resid	2.13E+12	Schwarz criterion		28.17942
Log likelihood	-484.2515	F-statistic		28.92039
Durbin-Watson stat	2.007691	Prob(F-statistic)		0.000000

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice C – Correlograma da série - ICMS estacionária.

Sample: 2001Q1 2010Q4
Included observations: 39

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.229	-0.229	2.1972	0.138
		2	-0.363	-0.438	7.8919	0.019
		3	-0.094	-0.409	8.2850	0.040
		4	0.378	0.046	14.827	0.005
		5	-0.039	-0.055	14.899	0.011
		6	-0.203	-0.082	16.897	0.010
		7	0.011	0.005	16.902	0.018
		8	0.152	-0.002	18.100	0.020
		9	-0.131	-0.181	19.012	0.025
		10	-0.017	-0.040	19.027	0.040
		11	0.047	-0.064	19.154	0.058
		12	0.042	-0.073	19.261	0.082
		13	0.035	0.158	19.337	0.113
		14	-0.049	0.073	19.491	0.147
		15	0.018	0.097	19.512	0.191
		16	-0.013	0.077	19.524	0.242

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice D – Estimação do modelo ARIMA(1,1,3)

Dependent Variable: D(ICMS)
 Method: Least Squares
 Sample (adjusted): 2001Q4 2010Q4
 Included observations: 37 after adjustments
 Convergence achieved after 43 iterations
 Backcast: 2001Q1 2001Q3

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	46256.79	16312.25	2.835709	0.0079
AR(2)	-1.073277	0.046859	-22.90455	0.0000
MA(1)	-0.565344	0.159950	-3.534503	0.0013
MA(2)	0.937864	0.087942	10.66463	0.0000
MA(3)	-0.523986	0.155398	-3.371898	0.0020
R-squared	0.565544	Mean dependent var		64371.52
Adjusted R-squared	0.511238	S.D. dependent var		348315.7
S.E. of regression	243512.9	Akaike info criterion		27.76882
Sum squared resid	1.90E+12	Schwarz criterion		27.98651
Log likelihood	-508.7231	F-statistic		10.41385
Durbin-Watson stat	1.989797	Prob(F-statistic)		0.000016
Inverted MA Roots	.56	.00-.97i	.00+.97i	

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice E – Correlograma dos resíduos do modelo ARIMA(1,1,3)

Sample: 2001Q4 2010Q4

Included observations: 37

Q-statistic probabilities adjusted for 4 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.003	0.003	0.0003	
		2	0.123	0.123	0.6282	
		3	-0.172	-0.175	1.8857	
		4	0.068	0.060	2.0895	
		5	0.018	0.060	2.1039	0.147
		6	-0.011	-0.062	2.1091	0.348
		7	-0.064	-0.052	2.3061	0.511
		8	-0.055	-0.035	2.4572	0.652
		9	-0.211	-0.225	4.7553	0.446
		10	0.052	0.064	4.9021	0.556
		11	0.018	0.068	4.9196	0.670
		12	-0.031	-0.134	4.9751	0.760
		13	0.008	0.063	4.9788	0.836
		14	-0.043	-0.005	5.0963	0.885
		15	-0.021	-0.115	5.1251	0.925
		16	0.007	0.038	5.1287	0.954

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice F – Alisamento exponencial multiplicativo

Sample: 2001Q1 2010Q4

Included observations: 40

Method: Holt-Winters Multiplicative Seasonal

Original Series: ICMS

Forecast Series: ICMSM1

Parameters:	Alpha	0.4100
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	1.91E+12
	Root Mean Squared Error	218680.5

End of Period Levels:	Mean	3202749.
	Trend	49677.97
	Seasonals:	
	2010Q1	1.031208
	2010Q2	0.906311
	2010Q3	0.982730
	2010Q4	1.079752

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice G – Alisamento exponencial aditivo

Sample: 2001Q1 2010Q4
 Included observations: 40
 Method: Holt-Winters Additive Seasonal
 Original Series: ICMSDREGTRI
 Forecast Series: ICMSDRSM2

Parameters:	Alpha	0.3700
	Beta	0.0000
	Gamma	0.0000
	Sum of Squared Residuals	2.12E+12
	Root Mean Squared Error	230165.9

End of Period Levels:	Mean	3199412.
	Trend	49677.97
	Seasonals:	
	2010Q1	39289.50
	2010Q2	-203146.4
	2010Q3	-39755.36
	2010Q4	203612.3

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice H – Função de transferência

Dependent Variable: ICMS

Method: Least Squares

Sample (adjusted): 2001Q4 2010Q4

Included observations: 37 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-544562.0	238119.5	-2.286928	0.0285
ICMSDREGTRI(-3)	0.540059	0.101351	5.328585	0.0000
FPMDREGTRI	0.082118	0.014100	5.824140	0.0000
R-squared	0.802310	Mean dependent var		2102447.
Adjusted R-squared	0.790681	S.D. dependent var		604904.6
S.E. of regression	276752.0	Akaike info criterion		27.97724
Sum squared resid	2.60E+12	Schwarz criterion		28.10785
Log likelihood	-514.5789	F-statistic		68.99333
Durbin-Watson stat	1.838514	Prob(F-statistic)		0.000000

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice I – Combinação das previsões

Dependent Variable: ICMSDREGTRI

Method: Least Squares

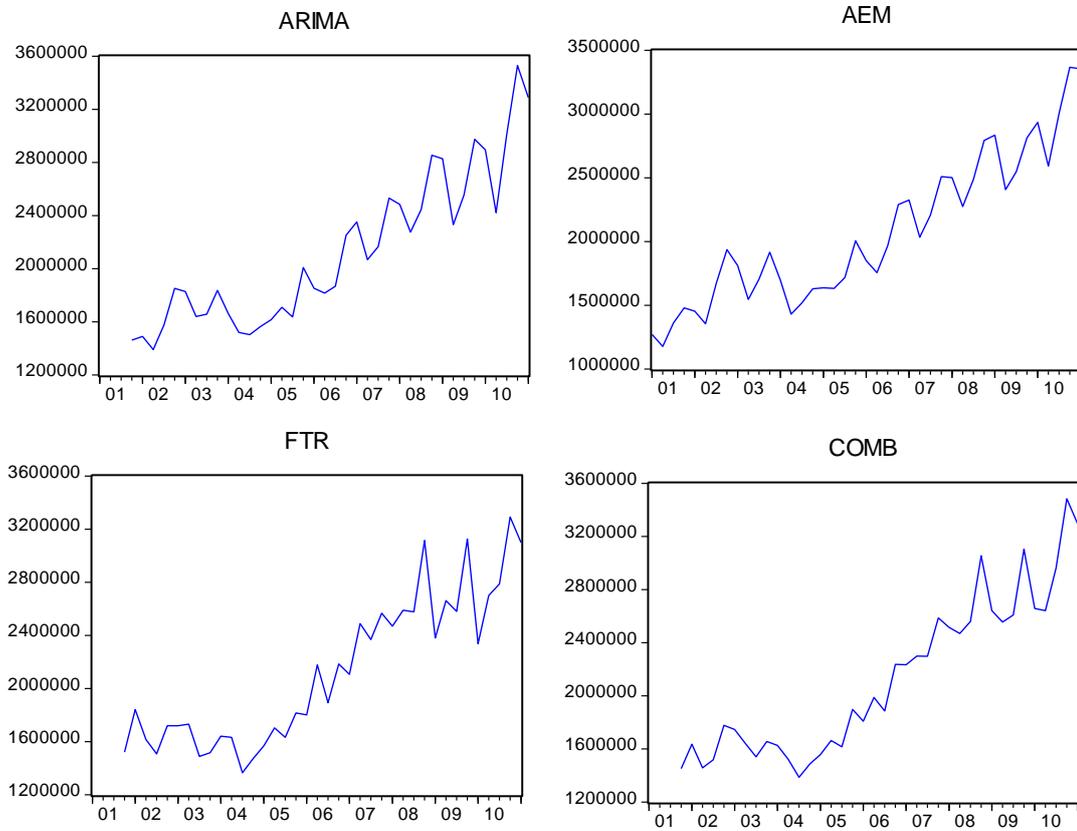
Sample (adjusted): 2001Q4 2010Q4

Included observations: 37 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-164669.1	151648.0	-1.085864	0.2850
0.18*AEM+0.30*ARIMA+0.52*FTR	1.080467	0.070186	15.39439	0.0000
R-squared	0.871318	Mean dependent var		2102447.
Adjusted R-squared	0.867641	S.D. dependent var		604904.6
S.E. of regression	220071.5	Akaike info criterion		27.49383
Sum squared resid	1.70E+12	Schwarz criterion		27.58091
Log likelihood	-506.6359	F-statistic		236.9873
Durbin-Watson stat	1.853194	Prob(F-statistic)		0.000000

Fonte: Elaborado pela autora com o auxílio do software Eviews.

Apêndice J - Valores estimados com os modelos ARIMA(1,1,3), Alisamento exponencial Multiplicativo, Função de Transferência e combinação de previsões – período de janeiro de 2001 a março de 2011.



Fonte: Elaborado pela autora com o auxílio do software Eviews