

**UNIVERSIDADE FEDERAL DO CEARÁ  
CENTRO DE APERFEIÇOAMENTO DE ECONOMISTAS DO NORDESTE –  
CAEN  
MESTRADO PROFISSIONAL EM ECONOMIA**

**Cristovam Colombo dos Santos Cruz**

**ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO MENSAL DO ICMS: O  
CASO DO PIAUÍ**

**FORTALEZA  
2007**

**CRISTOVAM COLOMBO DOS SANTOS CRUZ**

**ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO MENSAL DO ICMS: O  
CASO DO PIAUÍ**

Dissertação de Mestrado apresentada  
ao Curso de Pós-Graduação em  
Economia da Universidade federal do  
Ceará CAEN/UFC, como requisito para  
a obtenção do grau de Mestre em  
Economia, Categoria Profissional.

Orientador: Prof. Dr. Fabrício Carneiro  
Linhares

FORTALEZA  
2007

C964a Cruz, Cristovam Colombo dos Santos

Análise de séries temporais para previsão mensal do ICMS: o caso do Piauí / Cristovam Colombo dos Santos Cruz. Fortaleza, 2007

81 f.

Orientador: Prof. Dr. Fabrício Carneiro Linhares  
Dissertação (Mestrado Profissional) - Universidade Federal do Ceará. Curso de Pós-Graduação em Economia – CAEN, Fortaleza, 2007.

1. ICMS 2. Econometria 3. Modelo ARIMA.

I. Título

CDD – 336

**CRISTOVAM COLOMBO DOS SANTOS CRUZ**

**ANÁLISE DE SÉRIES TEMPORAIS PARA PREVISÃO MENSAL DO ICMS: O  
CASO DO PIAUÍ**

Dissertação aprovada pelo Curso de Pós-Graduação em Economia-CAEN da Universidade Federal do Ceará como requisito parcial para a obtenção do grau de Mestre em Economia, Categoria Profissional.

Aprovada em: \_\_\_/\_\_\_/\_\_\_/

**BANCA EXAMINADORA**

-----  
Prof. Dr. Fabrício Carneiro Linhares (Orientador)  
Universidade Federal do Ceará - UFC

-----  
Prof. Dr. Roberto Tatiwa Ferreira  
Universidade Federal do Ceará - UFC

-----  
Prof. Dr. Ricardo Brito Soares  
Universidade Federal do Ceará - UFC

A Deus, pela vida,

Aos meus pais, pela educação que me deram,

Aos meus filhos Cristina, Ricardo e Priscilla, pela alegria de tê-los como filhos,

À minha esposa Margarete, pelo companheirismo, pela cumplicidade, pelo incentivo e pelo amor que me cativa há 29 anos.

## **AGRADECIMENTOS**

À Faculdade Santo Agostinho – FSA, na pessoa de sua diretora, Professora Yara Lira, que, por confiar em mim, concedeu-me bolsa para financiamento dos estudos.

Aos colegas da Secretaria da Fazenda do Estado do Piauí e da Fundação CEPRO pela colaboração nos levantamentos dos dados da pesquisa.

Aos professores do CAEN, sempre compreensivos e pacientes com nossas deficiências e de um modo especial aos professores Fabrício e Roberto, que, sempre de forma amigável, orientaram-me na realização desta dissertação.

Ao pessoal do IPEPLAN, na pessoa da Professora Rossana, que sempre nos acolheu de forma calorosa na cidade de Parnaíba.

## RESUMO

Esta Dissertação trata de pesquisa sobre a análise de séries temporais para previsão mensal do Imposto Sobre Circulação e Mercadorias e Prestação de Serviços – ICMS no estado do Piauí. Objetiva-se com essa pesquisa oferecer aos gestores do estado um modelo de previsão consistente e com bom poder preditivo, de forma a contribuir com a gestão financeira estadual. No trabalho, utilizaram-se os modelos ARIMA e Função de Transferência para realizar previsões, bem como o Modelo Combinação de Previsões. A dissertação apresenta um diagnóstico do ICMS no estado do Piauí e uma revisão da literatura onde são abordados os principais aspectos teóricos dos modelos utilizados no trabalho, bem como a análise dos resultados empíricos. Ao final, pode-se observar que os resultados obtidos na presente dissertação, estão em sintonia com outros resultados obtidos em trabalhos semelhantes realizados sobre o tema, o que vem a confirmar a importância dos modelos que utilizam a análise de séries temporais como instrumento de predição.

Palavras-chave: ICMS; Modelo ARIMA; Modelo Função de Transferência.

## **ABSTRACT**

This dissertation deals with a research on the temporal series analysis for the monthly forecast of the turnover and services tax – ICMS in Brazil – in the state of Piauí. The aim of this research is to offer the statewide policymakers a consistent forecast and powerfully predictive model, so as to contribute to the state finance management. In this work, the ARIMA and Assignment Function models were used to carry out forecasts, as well as Forecast Combination. The dissertation presents a diagnosis of the ICMS in the state of Piauí, a review on the literature where the main theoretical aspects of the models carried out in the work are addressed, in addition to the empirical findings analysis. As a conclusion, it can be observed that the findings carried out in this dissertation are in harmony with other results of similar works carried out on the theme, which corroborates the importance of the models using the temporal series analysis as a forecasting instrument.

Keywords: ICMS; ARIMA Model; Assignment Function Model.

**LISTA DE GRÁFICOS**

Gráfico 1	– Evolução da Arrecadação do ICMS	24
Gráfico 2	– Séries Temporais das Variáveis da Pesquisa – Valores Reais	46
Gráfico 3	– Valores Realizados e Estimados pelo modelo ARMA – Período de Jan/96 a Jun/06	48
Gráfico 4	- Correlação ICMSR versus FPER – Jan/96 a Des/06	49
Gráfico 5	– Valores Realizados e Estimados pelo modelo Função de Transferência – Período de Jan/96 a Jun/06	50
Gráfico 6	– Valores Realizados e Estimados – Modelo ARMA (2,3) – Período de Jan/96 a dez/06	53
Gráfico 7	- Valores Realizados e Estimados – Modelo Função de Transferência – Período de Jan/96 a dez/06	55

## LISTA DE TABELAS

Tabela 1	– Relação FPE/ICMS	21
Tabela 2	– Receitas Tributárias	21
Tabela 3	– Arrecadação Por Regional	22
Tabela 4	– Arrecadação Por Atividade Econômica	22
Tabela 5	– Desempenho da Anistia	23
Tabela 6	– Desempenho do Piauí em Relação às Demais UF	25
Tabela 7	– Comportamento das FAC e FACP de um Processo ARIMA( $p, d, q$ )	65
Tabela 8	– Teste ADF da Série ICMSR: Período de Jan/06 a Dez/06	66
Tabela 9	– Teste ADF da Série FPER: Período de Jan/06 a Dez/06	67
Tabela 10	– Teste ADF da Série CONCIM: Período de Jan/06 a Dez/06	68
Tabela 11	– Teste ADF da Série CONENEG: Período de Jan/06 a Dez/06	69
Tabela 12	– Teste ADF da Série CREFFISCR: Período de Jan/06 a Dez/06	70
Tabela 13	– Teste ADF da Série NUNFIS: Período de Jan/06 a Dez/06	71
Tabela 14	- Critérios de Schwarz para ARMA( $p, q$ ) – Máximo e Mínimo	72
Tabela 15	– Estimação do Modelo ARMA(1,0)	73
Tabela 16	– Correlograma dos Resíduos da estimação do Modelo ARMA (1,0)	74
Tabela 17	– Critérios de Schwarz para Função de Transferência – Defasagens de 1 a 5	75
Tabela 18	– Estimação do Modelo da Função de Transferência	76
Tabela 19	- Correlograma dos Resíduos da Estimação da Função de Transferência	77
Tabela 20	- Valores Previstos e Realizados do ICMSR Mensal	51
Tabela 21	- Valores Previstos e Realizados do ICMSR Mensal	51

Tabela 22	– Critérios de Schwarz para ARMA ( $p$ e $q$ ) Reestimados – Máximo e Mínimo	78
Tabela 23	– Reestimação do Modelo ARMA (2,3)	79
Tabela 24	– Critérios de Schwarz para Função de Transferência - Defasagens de 1 a 5	80
Tabela 25	– Reestimação da Função de Transferência - Período de Jan/96 a Jun/06	81
Tabela 26	– Valores Previstos e Realizados do ICMSR Mensal	55
Tabela 27	- Valores Previstos e Realizados do ICMSR Mensal	56
Tabela 28	- Valores Previstos e Realizados do ICMSR Mensal, incluindo método SEFAZ	57

## SUMÁRIO

<b>Lista de Gráficos</b>	8
<b>Lista de Tabelas</b>	9
<b>INTRODUÇÃO</b>	12
<b>1. IMPOSTO SOBRE CIRCULAÇÃO DE MERCADORIAS E PRESTAÇÃO DE SERVIÇOS – ICMS</b>	15
1.1. Aspectos Legais do ICMS	16
1.2. Características do ICMS	16
1.2.1. Princípios constitucionais norteadores do imposto	17
1.2.2. Âmbito do incidência do imposto	17
1.2.3. Sujeição Passiva	18
1.2.4. Alíquotas	19
1.2.5. Base de cálculo	20
1.3. O Comportamento do ICMS no Piauí	20
<b>2. REVISÃO DA LITERATURA</b>	26
2.1. Trabalhos na Área de Previsão do ICMS	26
2.2. Tipos de Métodos de Previsão	27
2.3. Modelos ARIMA	30
2.4. Previsão com Modelos ARIMA	38
2.5. Função de Transferência	39
2.6. Combinação de Previsões	40
2.7. Métodos de Performance Preditiva	42
<b>3. ANÁLISE DOS RESULTADOS</b>	44
3.1. Ajustes nas Séries	45
3.2. Testes de Raiz Unitária	45
3.3. Estimacão dos Modelos de Previsão do ICMS Mensal	46
3.3.1. Modelo ARMA	46
3.3.2. Modelo Função de Transferência	48
3.3.3. Previsões	50
3.4. Reestimacão dos Modelos de Previsão da Arrecadação do ICMS mensal	52
3.4.1. Modelo ARMA	52
3.4.2. Modelo Função de Transferência	53
3.4.3. Previsões	55
<b>CONCLUSÃO</b>	59
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	61
<b>ANEXOS</b>	64

## INTRODUÇÃO

A cada dia os recursos à disposição dos entes públicos se tornam mais escassos, face, principalmente, ao aumento da demanda por serviços públicos de qualidade. Não obstante o esforço dos gestores públicos no sentido de reduzir seus gastos e aumentar suas receitas próprias, observa-se um crescente endividamento, o qual tem origem no gasto realizado em quantidade superior à receita gerada.

Exige-se do gestor público competência no gerenciamento do caixa estatal, de forma que a despesa pública fique aquém da receita efetivamente arrecadada. Tal missão é ingrata vez que o gestor precisa estimar a receita com antecedência, de modo a dimensionar a despesa que poderá ser realizada no período seguinte.

Trata-se, pois, de uma atividade de previsão que, dependendo de sua acurácia, pode facilitar o gerenciamento do caixa público, evitando desperdício com pagamento de juros, compras superfaturadas, bem como diminuindo a pressão sobre os gastos, haja vista que tudo foi previsto no orçamento a partir da receita possível de ser realizada.

Dessa forma, a atividade de previsão de receitas ganha importância do ponto de vista gerencial, pois permite que o administrador público tenha a sua disposição um instrumento seguro de apoio a tomada de decisão, que lhe permitirá um melhor planejamento das finanças do Estado, proporcionando a otimização da programação das políticas públicas.

Vista sob o prisma da legalidade, a atividade de previsão ganha relevo a partir do momento em que ela é obrigatória. Disciplina a lei complementar 101, de 04 de maio de 2000 (lei de responsabilidade fiscal), que “constituem requisitos essenciais da responsabilidade na gestão fiscal a instituição, previsão e efetiva arrecadação de todos os tributos da competência constitucional do ente da Federação”(grifo nosso). Ainda, “as previsões de receita observarão as normas técnicas e legais, considerarão os efeitos das alterações na legislação, da variação do índice de preços, do crescimento econômico ou de qualquer outro fator relevante e serão acompanhadas de demonstrativo de sua evolução nos últimos três anos, da projeção para os dois

seguintes àquele a que se referirem, e da metodologia de cálculo e premissas utilizadas”.

O zelo da lei complementar se justifica pelo fato de que o orçamento é uma peça elaborada pelo executivo e aprovada pelo legislativo, mas que vincula todos os poderes. Assim, manobras oriundas do executivo no sentido de manipular para baixo a receita, podem ser detectadas pelos outros poderes a partir da consulta à memória dos cálculos da previsão realizada.

Neste sentido, o presente trabalho tem, por propósito, idealizar um modelo de previsão de receita para o Imposto Sobre Circulação de Mercadorias e Serviços – ICMS, por ser esse tributo o responsável por 31,36% da receita corrente líquida estadual, utilizando os modelos de análises de séries temporais, que tenha uma performance e embasamento científico melhor que o atualmente usado pela Secretaria da Fazenda do Estado do Piauí.

Para consecução do trabalho, optou-se por realizar a previsão a partir de análise de modelos de séries temporais, onde será utilizada a metodologia auto-regressiva integrada de média móvel – ARIMA, a Função de Transferência e a combinação das duas metodologias. Na realidade serão comparadas as previsões dos modelos ARIMA, da Função de Transferência e a combinação de ambas, com o objetivo de se modelar a melhor previsão de arrecadação do ICMS para o estado do Piauí.

O trabalho está estruturado em quatro capítulos. O primeiro é destinado aos aspectos gerais do ICMS e da economia piauiense. Neste capítulo serão realizados comentários sobre as origens do imposto, sobre os princípios que norteiam essa espécie tributária e por fim sobre o comportamento do imposto no tocante à concentração, desempenho por atividade econômica, bem como sobre as ações que objetivam o incremento da arrecadação do tributo.

O segundo, destinar-se-á a revisão da literatura, onde serão abordados alguns trabalhos já realizados sobre o tema, bem como sobre os aspectos teóricos relativos à análise de séries temporais, da função de transferência e da técnica de combinação de previsões.

Por fim, o terceiro capítulo abordará o resultado empírico da pesquisa e o último capítulo é reservado para as conclusões e recomendações finais sobre o trabalho.

## **1. O IMPOSTO SOBRE A CIRCULAÇÃO DE MERCADORIAS E SOBRE A PRESTAÇÃO DE SERVIÇOS TRANSPORTE INTERMUNICIPAL E INTERESTADUAL E DE COMUNICAÇÃO - ICMS**

Os impostos podem ser classificados de diversas formas, dependendo do enfoque que se queira ressaltar. Do ponto vista da incidência econômica, eles se classificam em impostos diretos e indiretos (Montoro Filho 2002, pág. 560).

O imposto direto é aquele que incide sobre a renda e riqueza (patrimônio). Nele a pessoa que recolhe o imposto (contribuinte de direito) é quem arca com o ônus tributário (contribuinte de fato), ou seja, o contribuinte de direito é a mesma pessoa do contribuinte de fato.

Por outro lado, o imposto indireto, que incide sobre as operações de circulação de mercadorias e sobre as prestações de serviços, tem como característica a dicotomia entre as duas espécies de contribuintes. Nesta espécie tributária quem tem o dever legal de recolher o imposto não é aquele que arca com o ônus do tributo, portanto o contribuinte de direito e de fato são pessoas distintas.

O ICMS enquadra-se entre os impostos indiretos e tem como campo de incidência as operações de circulação de mercadorias e as prestações de serviços de transporte interestadual e intermunicipal e de comunicação. Após a constituição de 1988, esta espécie tributária teve sua base de incidência alargada com a inclusão das prestações de serviços e o que era somente ICM passou a denominar-se de ICMS, devido à inclusão dos serviços de transporte e comunicação na caracterização de seu fato gerador.

Uma crítica feita ao ICMS é que se trata de um imposto regressivo, isto é, o aumento da contribuição (ônus tributário) é proporcionalmente menor que o incremento da renda. A relação entre a carga tributária e renda decresce com o aumento do nível da renda, portanto as camadas sociais com menor renda são taxadas com uma carga maior, o que fere o princípio constitucional tributário da capacidade contributiva.

O ICMS tem função predominantemente fiscal, haja vista que sua principal finalidade é arrecadar recursos para o erário estadual. Portanto, para as economias dos Estados e do Distrito Federal, o ICMS é inegavelmente a

principal fonte de receita, tanto é verdade que, como no caso do Piauí, ele representa 31,36% da receita corrente líquida estadual, ficando atrás apenas do Fundo de Participação dos Estados - FPE.

Às vezes é utilizado com função extrafiscal, como no caso da concessão de isenção com o fim de atrair investimentos para os estados e distrito federal, o que ocasiona a denominada guerra fiscal (Machado, 2004). Tal prática traz conseqüências para o pacto federativo, razão pela qual a constituição estabelece que cabe à lei complementar estabelecer normas de procedimento para a concessão de benefícios e incentivos fiscais no âmbito do ICMS.

### **1.1. Aspectos Legais do ICMS**

O ancestral do ICMS foi o antigo Imposto Sobre Vendas e Consignações - IVC, previsto na constituição de 1946. Posteriormente, na constituição de 67, passou a denominar-se de Imposto Sobre a Circulação de Mercadorias e, mais recentemente sob a égide da constituição de 1988, foi acrescida a sua base de incidência os serviços de transporte e de comunicação, passando a chamar-se de ICMS. Portanto, sua genealogia estabelece que o IVC gerou o ICM, que por sua vez gerou o ICMS (Carraza 2006, pág. 32).

A atribuição da competência para que os Estados e Distrito Federal possam criar o ICMS, está prevista no art. 155, inciso II, da constituição federal. Aquele dispositivo estabelece que “compete aos Estados e ao Distrito Federal instituir impostos sobre: operações de circulação de mercadorias e sobre as prestações de serviços de transporte interestadual e intermunicipal e de comunicação”.

A nível estadual o imposto foi instituído através da lei n° 4.257/89 e regulamentado por meio do decreto n° 7.560/89. Ambas as normas atendem ao direcionamento estabelecido pela Lei Complementar n° 87/96, denominada de lei Kandir.

### **1.2 Características do ICMS**

### **1.2.1 Princípios constitucionais norteadores do imposto**

O ICMS é informado por dois princípios constitucionais específicos, quais sejam:

I - princípio da não-cumulatividade, que consiste em compensar o imposto devido em cada etapa de circulação da mercadoria com o imposto pago na etapa anterior. Na prática, devido ao ICMS incidir sobre todas as etapas de circulação das mercadorias (produção, circulação e consumo), e tendo como objetivo evitar a cobrança de tributo sobre tributo, permite-se ao contribuinte que realiza operação de circulação com mercadoria abater o valor do ICMS pago na etapa anterior, cujo efeito final consiste em cobrar o imposto apenas sobre o valor agregado na comercialização.

II - princípio da seletividade: contrariamente ao ICM, que era um tributo uniforme (mesmas alíquotas para todas as mercadorias), o ICMS poderá ser seletivo em função da essencialidade das mercadorias ou serviços. Por meio desse princípio é possível atribuir ao ICMS uma função extrafiscal, através da aplicação de alíquotas menos gravosas àquelas mercadorias ou serviços convenientes à sociedade e alíquotas mais severas àquelas mercadorias ou serviços consideradas supérfluos ou inconvenientes à população.

### **1.2.2. Âmbito de incidência do ICMS.**

O âmbito de incidência do ICMS é delimitado na própria constituição, ao atribuir a competências para os Estados e Distrito federal, porém coube a lei complementar estabelecer normas gerais em matéria de legislação tributária, principalmente sobre a definição dos fatos geradores dos tributos. No tocante ao ICMS, a lei complementar n °87/96 cumpriu este mister.

Por esta lei, o ICMS incide sobre as:

- I - operações relativas à circulação de mercadorias, inclusive o fornecimento de alimentação e bebidas em bares, restaurantes e estabelecimentos similares;
- II - prestações de serviços de transporte interestadual e intermunicipal, por qualquer via, de pessoas, bens, mercadorias ou valores;

III - prestações onerosas de serviços de comunicação, por qualquer meio, inclusive a geração, a emissão, a recepção, a transmissão, a retransmissão, a repetição e a ampliação de comunicação de qualquer natureza;

IV - o fornecimento de mercadorias com prestação de serviços;

V - entrada de mercadoria importada do exterior, por pessoa física ou jurídica, ainda quando se tratar de bem destinado a consumo ou ativo permanente do estabelecimento, bem como a aquisição, em licitação promovida pelo poder público, de mercadoria ou bens importados do exterior e apreendidos;

VI - saída de mercadoria em hasta pública;

VII - entrada, em estabelecimento de contribuinte, de mercadoria oriunda de outra Unidade da Federação, destinada a consumo ou ativo permanente;

VIII - utilização, por contribuinte, de serviço cuja prestação se tenha iniciado em outra Unidade da Federação e não esteja vinculada a operação ou prestação subseqüentes;

### **1.2.3. Sujeição Passiva.**

No pólo passivo da relação jurídica tributária, nascida a partir da ocorrência do fato gerador, gravitam o contribuinte e o responsável tributário. Sendo contribuinte ou responsável, a capacidade tributária passiva só pode onerar aquele que participou da ocorrência do fato típico, de forma que ninguém pode ser compelido ao pagamento do ICMS sem que tenha participado de algum modo da realização do fato típico.

Contribuinte é aquele que tem relação pessoal e direta com a situação que constitua o respectivo fato gerador. Assim, pode ser contribuinte todo aquele de praticar o ato tido como fato gerador do imposto, independentemente de ser pessoa física ou jurídica, no entanto é preciso que a pessoa envolvida pratique com habitualidade ou em volume que caracterize intuito comercial operações ou prestações sob a incidência do imposto.

Responsável é aquele que, sem revestir a condição de contribuinte, está obrigado ao pagamento do imposto em decorrência de disposição expressa em lei, ou seja, a responsabilidade pelo pagamento do débito

tributário recai sobre quem não tem relação pessoal e direta com o fato gerador, mas de alguma forma a ele está vinculado.

A responsabilidade ocorre por:

I - substituição: quando, em função da lei, o contribuinte originário é substituído por um terceiro, que passa a ser o principal responsável pelo cumprimento da obrigação tributária daquele. O terceiro é responsável de receber o imposto do contribuinte e repassar ao fisco.

II - transferência: quando, em consequência de um fato contrário às normas tributárias ou em função do interesse comum na situação constituidora do fato gerador, uma terceira pessoa é compelida a satisfazer a obrigação tributária, pagando uma dívida alheia.

Muito polêmico é o instituto da substituição tributária, que consiste em substituir o contribuinte por um responsável tributário, o qual fica obrigado ao adimplemento do débito tributário. A crítica se dá quando ocorre a substituição tributária para frente, pois através desta técnica o imposto é pago de forma antecipada, via retenção na fonte ou nos postos fiscais de fronteira, antes mesmo que haja a efetiva circulação da mercadoria pelo contribuinte adquirente do produto. Tal prática é justificada pelo fisco como sendo uma forma de evitar a sonegação, bem como de facilitar a fiscalização.

#### **1.2.4. Alíquotas**

Na constituição anterior, o antigo ICM não tinha função extrafiscal, isto é, não era seletivo, por essa razão as alíquotas eram uniformes, variando apenas em função de ser a operação interna, interestadual ou de exportação (Machado 2004, pág. 363). Com a constituição de 1988, foram instituídas as alíquotas internas e as interestaduais.

Utilizam-se as alíquotas internas quando: as operações se realizarem dentro de uma mesma unidade da federação, as mercadorias sejam importadas do exterior, as mercadorias forem arrematadas ou quando o destinatário da mercadoria situado em outra unidade federativa não for contribuinte do ICMS.

Por outro lado, quando a operação for realizada entre contribuintes situados em diversos estados membros, aplica-se a alíquota interestadual, a qual é de 7% ou 12%, dependendo da origem ou do destino da mercadoria.

### **1.2.5. Base de Cálculo**

É a grandeza econômica ou numérica que mensura a materialidade da hipótese de incidência, sobre a qual se aplica a alíquota para se obter o “quantum” a pagar. Geralmente é o próprio valor da operação relativa à circulação da mercadoria ou o preço do serviço prestado, que neste caso chama-se de base de cálculo efetiva. No entanto, a lei estabelece outras formas de base de cálculo específicas, tipo: estimada, reajustável ou arbitrada.

Dependendo da hipótese de incidência, existe uma forma específica para se aferir o valor da base de cálculo. Assim, quando a hipótese de incidência for a saída de mercadoria do estabelecimento, a base tributável será o valor da operação, onde se incluem, além do valor da mercadoria, as despesas debitadas ao adquirente e os descontos incondicionais a este concedido. Por outro lado, quando se tratar de incidência decorrente de importação de mercadorias do exterior, a base de cálculo corresponderá à soma do valor da mercadoria ou bem constante dos documentos de importação, do valor do imposto de importação - II, do valor do imposto sobre produtos industrializados - IPI, do valor do imposto sobre operações de câmbio - IOF e das outras despesas aduaneiras debitadas ao importador.

### **1.3. O Comportamento do ICMS no Piauí**

As receitas correntes do estado do Piauí são constituídas pelas receitas tributárias (decorrentes da tributação sobre o patrimônio privado), patrimoniais (oriundas do próprio patrimônio público), de transferências (recebidas de outras pessoas de direito público ou privado, independente de contraprestação direta de bens ou serviços) e outras receitas (decorrentes do recebimento de juros, multas indenizações, etc.).

O estado piauiense é dependente, como a maioria dos estados do norte e nordeste, dos recursos transferidos pela União, a título de Fundo de Participação dos Estados – FPE. No ano de 2006, 40,39% da receita corrente era constituída pelo FPE e 31,36% pelo ICMS. Porém, essa realidade tende a

se inverter, haja vista o esforço feito pela administração tributária no sentido de melhorar o nível de arrecadação própria, o que pode ser verificado na Tabela 1.

**Tabela - 1 - Relação FPE/ICMS**

<b>Ano</b>	<b>FPE</b>	<b>ICMS</b>	<b>Relação FPE/ICMS</b>
1995	333.707.038,45	219.047.063,07	1,52
1996	377.516.597,38	281.135.210,28	1,34
1997	423.687.915,90	305.551.587,98	1,39
1998	471.912.086,52	320.629.125,58	1,47
1999	522.659.917,99	340.619.589,33	1,53
2000	619.356.191,52	426.821.064,56	1,45
2001	728.867.552,38	467.972.606,19	1,56
2002	902.034.776,15	540.797.415,77	1,67
2003	938.389.899,35	610.695.028,01	1,54
2004	1.034.367.884,60	760.498.178,54	1,36
2005	1.294.564.437,13	901.060.847,00	1,44
2006	1.423.717.489,29	1.071.811.008,12	1,34

Fonte: Balanço Geral do Estado

Tomando-se por base apenas a receita tributária, pode-se observar que o ICMS é, de longe, o item de receita mais representativo. No ano de 2006, a arrecadação desse tributo correspondeu a 30,21 % da receita total. Relativamente aos outros tributos, verificou-se que ele representou 90,56 % da receita tributária, conforme se pode observar na Tabela 2.

**Tabela - 2 – Receitas Tributárias**

Em R\$

<b>RECEITAS TRIBUTÁRIAS</b>					
<b>DISCRIMINAÇÃO</b>	<b>2005</b>	<b>%</b>	<b>2006</b>	<b>%</b>	<b>VARIAÇÃO %</b>
<b>IMPOSTOS</b>	<b>990.131.167</b>	<b>95,68</b>	<b>1.183.545.195</b>	<b>95,81</b>	<b>19,53</b>
ICMS	901.060.847	91,00	1.071.811.008	90,56	18,95
IPVA	42.948.524	4,34	53.332.312	4,51	24,18
IRRF	45.349.971	4,58	57.302.070	4,84	26,36
ITCMD	771.825	0,08	1.099.805	0,09	42,49
<b>TAXAS</b>	<b>44.737.410</b>	<b>4,32</b>	<b>51.756.076</b>	<b>4,19</b>	<b>15,69</b>
<b>TOTAL</b>	<b>1.034.868.577</b>	<b>100</b>	<b>1.235.301.271</b>	<b>100</b>	<b>19,37</b>

Fonte: Balanço Geral do Estado

A arrecadação do ICMS do estado do Piauí tem como característica a concentração, tanto geográfica como por atividade econômica. No tocante ao aspecto geográfico, observa-se que 84,78 % da arrecadação do tributo está

concentrada na regional de Teresina, a qual é composta por 26 municípios. Desse total, a capital do estado, o município de Teresina, representa 83,71%. Isso é coerente, pois 26 % da população residem na capital, como também 38,22 % dos contribuintes do ICMS estão sediados nesse município. A Tabela 3 ilustra essa realidade.

**Tabela - 3 - % Arrecadação Por Regional**

<b>Regional</b>	<b>%</b>
1ª PARNAIBA	2.55
2ª CAMPO MAIOR	0.92
3ª TERESINA	84.78
4ª OEIRAS	0.97
5ª FLORIANO	2.41
6ª PICOS	4.33
7ª S. RAIMUNDO	1.93
8ª CORRENTE	0.85
9ª PIRIPIRI	1.26
<b>Total</b>	<b>100,00</b>

Fonte: Gerência de Arrecadação - GECAD

No que diz respeito à concentração decorrente da atividade econômica, verifica-se uma predominância do setor comércio na arrecadação do ICMS, o que não é estranho, pois o Piauí é um estado tipicamente consumidor, apresentando uma indústria incipiente. O comportamento da arrecadação do imposto por atividade econômica pode ser visualizado na Tabela 4.

**Tabela - 4 – Arrecadação por Atividade Econômica Econômica - Ano 2006**

<b>Atividade</b>	<b>Valor</b>	<b>R\$ mil</b>
		<b>%</b>
Agropecuária.Silvícola e Pesca	2.943	0,27
Industria de Transformação	134.724	12,57
Energia Elétrica	137.602	12,84
Comércio Atacadista	419.104	39,10
Comércio Varejista	186.902	17,44
Transporte	15.824	1,48
Comunicação	126.607	11,81
Outros Serviços	7.026	0,66
Outros Órgãos e Postos Fiscais	49.671	3,83
<b>Total</b>	<b>1.071.811</b>	<b>100,00</b>

Fonte: Gerência de Arrecadação - GECAD

Têm sido comum junto aos estados brasileiros, por autorização do Conselho de Política Fazendária – CONFAZ, deliberar pela concessão de anistias de juros e multas, bem como sobre prazos elásticos para parcelamento do ICMS. Somente no período da pesquisa, de 1996 a 2006, observaram-se cinco concessões desse tipo de benefício. Trata-se de um apelo extremado visando o aumento da arrecadação (reforço de caixa), coincidente com o final do ano, ocasião em que o ente estatal precisa de mais recursos para cumprir com o pagamento do décimo terceiro salário do funcionalismo.

O Piauí tem acompanhado as decisões do CONFAZ, o que nesses momentos de vigência da norma autorizativa do benefício, tem melhorado pontualmente a arrecadação, conforme pode se verificar na Tabela 5.

**Tabela - 5 - Desempenho da Anistia**

<b>Ano</b>	<b>Valor Anistia</b>	<b>Valor do ICMS-Ano</b>	<b>%</b>
1999	2.532.217,49	340.411.738,31	0,74
2002	6.198.093,55	544.056.373,92	1,40
2003	2.296.620,77	612.429.990,50	0,38
2005	16.819.292,65	902.279.619,19	1,86
2006	9.306.113,07	1.071.984.964,12	0,87

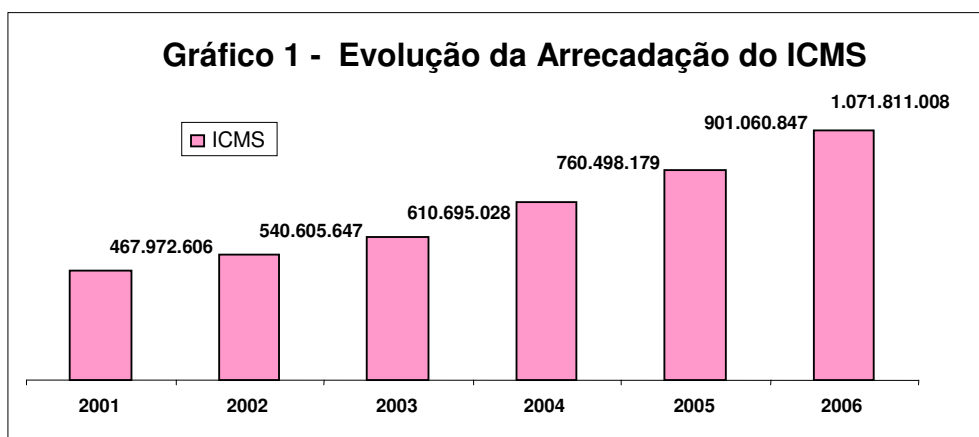
Fonte: Gerência de Arrecadação - GECAD

Muitas críticas têm sido colocadas contra a adoção de anistias para incrementar a arrecadação, principalmente pela área de fiscalização do tributo e pelos contribuintes adimplentes. Quanto aos primeiros, a crítica diz respeito ao fato de que não é pedagógico anistiar, pois isso levará a um relaxamento no cumprimento da obrigação tributária principal, ou seja, no pagamento do imposto devido. No tocante ao segundo, a queixa diz respeito ao fato de que há uma inversão de benefícios, onde os bons contribuintes, aqueles que cumprem com suas obrigações, são prejudicados por terem efetuado o pagamento de seus tributos em dias e os maus pagadores são beneficiados com pagamento extemporâneo do imposto sem a incidência de juros e multas. Ainda segundo eles, o correto seria bonificar os bons contribuintes, com redução no valor do imposto a ser pago, através de descontos.

No que respeita ao esforço para o incremento da arrecadação do ICMS, várias ações foram tomadas no período da pesquisa, tipo: implantação

do projeto de modernização a partir de 1996, modificação das alíquotas de energia elétrica e cigarros em 2004, bem como a inclusão de novos produtos na sistemática de pagamento antecipado do ICMS (substituição tributária) e por último a implantação da remuneração variável em 2006, incidente sobre o incremento da arrecadação. No primeiro caso, o governo do estado efetuou um empréstimo junto ao Banco Interamericano de Desenvolvimento - BID, no valor de 10 milhões de dólares e tendo como contrapartida local o mesmo montante, para a modernização da Secretaria da Fazenda, que contemplou a qualificação do servidor fazendário, a reforma e construção de imóveis, a aquisição de novos veículos para a fiscalização de trânsito, o desenvolvimento de sistemas integrados e a compra de equipamentos de informática e de comunicação. No que se refere à modificação das alíquotas, a energia elétrica teve sua alíquota majorada de 20% para 25% e os cigarros de 25% para 30%. No tocante à remuneração variável, instituída a partir de janeiro de 2006, esta consiste em incentivar o servidor fazendário no sentido de aumentar a arrecadação, a partir do pagamento de uma gratificação para o incremento da arrecadação – GIA, ou seja, caso atingido uma meta previamente definida, o grupo de tributação, arrecadação e fiscalização – TAF tem direito a uma participação que varia de 10% a 15% do valor do imposto incrementado.

O reflexo dessas ações foi positivo, conforme se pode observar no Gráfico 1.



Fonte: Balanço Geral do Estado – valores nominais

Todas essas ações têm contribuído para o aumento da arrecadação estadual em patamares superiores a de alguns estados do nordeste, bem como em relação à média do Brasil, conforme pode ser visto na Tabela 6.

**Tabela - 6 – Desempenho do Piauí em Relação às demais UF.**

Ano	% Incremento Real		Ranking Brasil
	Piauí	Brasil	
2004	16,94	10,50	4 °
2005	10,90	7,45	6 °
2006	14,11	8,19	5 °

Fonte: Gerência de Arrecadação - GECAD

## 2. REVISÃO DA LITERATURA

Este capítulo tem dois objetivos: 1) comentar alguns trabalhos já realizados na área de previsão do ICMS e 2) apresentar os conceitos principais de séries temporais, que servirão de suporte para o método de previsão a ser utilizado para resolução do problema proposto, bem como serão apresentados os meios de medição da eficiência das previsões realizadas.

### 2.1. Trabalhos na Área e previsão do ICMS

A utilização de séries temporais para previsão do ICMS é comum no meio científico. Vários trabalhos semelhantes sobre o tema existem e por isso merecem ser comentados.

Corvalão (2002), utilizou um modelo dinâmico – considera explicitamente o comportamento de uma variável no decorrer do tempo - para realizar a previsão da arrecadação do ICMS no estado de Santa Catarina. No seu trabalho, utilizou uma técnica econométrica que parte de uma abordagem geral para o específico, desenvolvida de acordo com a tradição econométrica da London School of Economy - LSE, isto é, um modelo econométrico geral, que captura as características essenciais de um conjunto de dados é reduzido até a seleção de um modelo estimado específico. A equação do modelo econométrico especificado continha o ICMS, defasado em 2 e 7 períodos, o Faturamento Mensal da Indústria, defasado 12 períodos, o Consumo de Energia Elétrica, defasado 6 e 10 períodos e a Consulta ao Serviço de Proteção ao Crédito, defasado 5 e 12 períodos. Quando comparados os valores realizados e os previstos, tomando como referência os doze meses de 2001, o modelo apresentou um erro percentual absoluto médio-EPAM de 2,59%.

Ferreira (1996), ao fazer previsão do ICMS para o estado do Ceará, utilizou uma combinação de previsões realizadas pelas técnicas do alisamento exponencial, modelo ARIMA e função de transferência. O modelo ARIMA especificado foi o ARIMA (1,0,4), enquanto o modelo Função de Transferência utilizou como variáveis o Fundo de Participação do Estado-FPE, defasado 1 período e o ICMS, defasado 2 períodos. No seu trabalho, verificou que o

método de combinação de modelos apresentou EPAM de 5,8% para previsão *ex-post.*, tendo sido utilizado o período de janeiro a junho de 1995, enquanto a previsão do modelo ARIMA, o que mais se destacou na forma individual, teve um EPAM de 5,9%. O principal motivo para o uso da técnica de combinação de previsões é diminuir o erro e consequentemente melhorar a performance preditiva.

Peceguini (2001), realizou estudos sobre a previsão do ICMS no estado de São Paulo, ocasião em que comparou os métodos: convencional, linha de tendência, série de tempo-decomposição clássica e auto-regressivo. No seu trabalho, que utilizou o período de jan/00 a dez/00 para fazer a previsão, foi constatado que o método séries de tempo-decomposição clássica teve o melhor desempenho. Para o período anual, observou-se um erro percentual absoluto médio de 4,6%, sem desconsiderar o efeito da anistia concedida pelo Governo do estado. Quando analisado o período semestral, ou seja os seis primeiros meses de 2000, o método proporcionou um EPAM de 0,5%.

No mesmo sentido, porém na área do imposto de renda, Santos (2003) utilizou o método da combinação de previsões para prever valores futuros do imposto. Empiricamente atingiu índice de 6,59 %, critério EPAM, para valores dentro da amostra (*ex-post*).

## **2.2. Tipos de Métodos de Previsão**

Para a realização de previsão, existem métodos qualitativos e quantitativos. Os primeiros dispensam a base de dados históricos e se assentam no subjetivismo de especialistas, por isso são conhecidos como métodos de julgamento (Silver, 2000). São recomendados para situações em que não se dispõe de dados em série, por exemplo quando se deseja prevê a venda de um produto novo.

Nos métodos quantitativos utilizam-se as séries históricas, pressupondo que os valores futuros seguem os padrões de comportamento da série passada. No entanto, esse método oferece limitações quando os padrões

de comportamento se alteram, ou seja, o padrão do futuro não é semelhante ao passado.

Neste trabalho, usar-se-á os métodos quantitativos para fazer previsão, os quais podem ser classificados em métodos causais e não causais.

Os métodos causais têm como pressuposto a existência relações de causalidade entre as variáveis, onde a variável a ser predita (variável dependente) tem o seu comportamento explicado por outra ou outras variáveis (variável independente). Esses métodos utilizam as técnicas de regressão estatística.

Já os métodos não causais, utilizam apenas a série histórica da variável a ser prevista para explicar o seu comportamento, pois parte do princípio de que a própria série contém todas as informações sobre o seu processo gerador. Esses métodos utilizam as técnicas de análise de séries temporais.

Noutro aspecto, os métodos de previsão quantitativos podem ser classificados em métodos univariados e multivariados.

Os métodos de previsão univariados são baseados na análise de uma única variável, que queremos prever. Aqui, o comportamento passado da variável a ser predita explica os seus valores futuros, portanto trata-se de análise de séries ordenadas no tempo.

Os métodos multivariados, por sua vez, utilizam a relação de correlação estatística existente entre várias variáveis independentes para estimar o comportamento futuro da variável a ser estimada, através da construção de modelos de regressão.

Este trabalho abordará tanto modelos univariados (ARIMA) como modelos multivariados (Função de Transferência).

No que diz respeito à série temporal, deve-se ter em mente que a mesma é um conjunto de observações ordenadas pelo tempo e que, dependendo da forma como for observada, se a todo instante ou em intervalos fixos de tempo, a série diz-se contínua ou discreta, respectivamente. Além disso, importa saber o seguinte:

- a série é formada por um processo estocástico, o qual é definido como uma família  $Z=\{Z(t), t \in T\}$ , tal que, para cada  $t \in T$ ,  $Z(t)$  é uma variável aleatória e  $T$  é um conjunto arbitrário (Morettin, 2006).

- uma série temporal  $Z(t)$  é uma realização ou uma trajetória do processo estocástico, logo para se especificar o processo, os parâmetros importantes são a média e a função de autocovariância, isto é, os momentos de primeira e segunda ordem, respectivamente (Morettin, 2006, pág. 22), os quais são dados por:

$$(2.1) \quad \mu(t) = E\{Z(t)\}$$

$$(2.2) \quad \gamma(t_1, t_2) = \text{Cov}\{Z(t_1), Z(t_2)\}$$

Uma questão que deve ser esclarecida quando se trabalha com séries temporais é saber se a mesma é ou não estacionária. A importância da questão deve-se ao fato de que a maioria dos procedimentos de análise estatística das séries temporais supõe que estas sejam estacionárias.

Intuitivamente, uma série temporal é estacionária quando ela se desenvolve no tempo aleatoriamente em torno de uma média constante, ou seja, independentemente da translação do tempo ela mantém as características. Porém, a literatura classifica a estacionariedade nas espécies abaixo:

a) série estritamente estacionária se a distribuição de probabilidade conjunta de  $Z(t_1), \dots, Z(t_k)$  é a mesma de  $Z(t_1+r), \dots, Z(t_k+r)$ , isto é, o deslocamento da origem dos tempos por uma quantidade  $r$  não tem efeito na distribuição conjunta, dependendo, portanto, apenas dos intervalos entre  $t_1, \dots, t_k$ . Logo, a média  $\mu(t)$  e a variância  $V(t)$  são constantes, isto é:

$$(2.3) \quad \mu(t) = \mu$$

$$(2.4) \quad V(t) = \sigma^2$$

b) série fracamente estacionária ou estacionária de segunda ordem ou estacionária em sentido amplo se satisfizer às seguintes condições:

$$(2.5) \quad E\{Z(t)\} = \mu(t) = \mu, \text{ constante, para todo } t \in T;$$

$$(2.6) \quad E \left\{ Z^2(t) \right\} < \infty, \text{ para todo } t \in T$$

$$(2.7) \quad \gamma(t_1, t_2) = \text{cov}\{Z(t_1), Z(t_2)\}, \text{ é uma função de } |t_1 - t_2|.$$

Outra forma de verificar se a série é estacionária, é aplicando o teste da raiz unitária de Dickey-Fuller Aumentado ou abreviadamente ADF. O problema da raiz unitária aparece quando o polinômio auto-regressivo apresenta uma raiz sobre o círculo unitário, o que implica que se deve fazer uma diferença da série original antes de ajustar o modelo, logo a série é não estacionária (Morettin 2006, pág. 486). O teste ADF consiste em saber se a hipótese nula (tem raiz unitária) é rejeitada, caso positivo a série é estacionária<sup>1</sup>.

### 2.3 Modelos ARIMA

O modelo ARIMA ou metodologia Box e Jenkins é bastante utilizado na modelagem de séries temporais, principalmente porque, em princípio, é possível manipular processos estocásticos de qualquer natureza, sejam eles estacionários ou não. Tal metodologia consiste na busca de um modelo auto-regressivo integrado de média móvel que se ajuste a um conjunto de dados e que descreva o processo estocástico gerador da série temporal.

Diferentemente dos modelos econométricos, onde a previsão se baseia na relação de correlação estatística entre variáveis e na inclusão de

---

<sup>1</sup> Para o modelo AR(n), o teste para a presença de raiz unitária se baseia na equação  $Y_t = \alpha + \beta_1 t + \beta_2 Y_{t-1} + \dots + u_t$ , em que  $\alpha$  é uma constante e  $t$  representa uma tendência determinística. Para tal equação estimada, têm-se como hipóteses:  $H_0: \beta_2 = 0$  (raiz unitária) e  $H_1: \beta_2 < 0$  (estacionaridade).

muitas variáveis explicativas, a previsão através do modelo ARIMA tem suporte nos dados da própria variável a ser explicada.

Assim, segundo este modelo a variável dependente se explica a partir dela própria. O seu princípio, de forma simples e genérica, estabelece que os elementos que explicam o comportamento de uma série temporal residem nos seus valores passados (auto-regressivos), bem como em um conjunto de erros aleatórios passados e correntes (termo de média-móvel) (Ferreira 1996, pág. 21).

Dependendo da série com a qual se esteja trabalhando, se estacionária ou não, o processo estocástico gerador da série pode ser descrito por um modelo específico. Dessa forma, para séries estacionárias os modelos apropriados são o auto-regressivo de ordem  $p$ : AR( $p$ ), o de média-móvel de ordem  $q$ : MA( $q$ ) e o auto-regressivo e de média-móvel, de ordem  $p$  e  $q$ : ARMA ( $p, q$ ).

Quando a série for não estacionária, o modelo apropriado é o auto-regressivo integrado de média-móvel de ordem  $p$ ,  $d$  e  $q$ : ARIMA ( $p, d, q$ ).

Para o modelo auto-regressivo - AR, a observação atual da v.a.  $X_t$  depende de suas próprias observações passadas imediatas e de um erro aleatório. Algebricamente, o modelo AR( $p$ ), pode ser definido por:

$$(2.8) \quad X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t$$

Observa-se uma similaridade com um modelo de regressão múltipla, onde os valores passados de  $X_t$ , fazem o papel de regressores. Assim, processos AR podem ser usados como modelo se for razoável assumir que o valor atual de uma série temporal depende de seu passado imediato mais um erro aleatório (Ehlers 2005, pág. 19).

Chamando B de operador de defasagem e o definindo como

$$(2.9) \quad BX_t = X_{t-1}, \text{ que generalizado torna-se } B_n X_t = X_{t-n}, \quad n = 0, 1, 2, \dots$$

Temos

(2.10)  $\phi(B) = 1 - \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p$ , chamado de polinômio  $\phi(B)$  de ordem  $p$ , ou operador auto-regressivo.

A condição de estacionaridade é satisfeita quando as raízes do polinômio  $\phi(B)$  estão fora do círculo unitário.

Um processo  $AR(p)$  tem a Função de Autocorrelação – FAC que decai de acordo com exponenciais e/ou senóides amortecidas, infinita em extensão (Morettin 2006, pág. 113).

Um modelo de média móvel de ordem  $q$  é dado por

$$(2.11) X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

onde  $\varepsilon_t$  é um erro aleatório formado por um processo de ruído branco<sup>2</sup>.

De outra forma

(2.12)  $X_t = \theta(B)\varepsilon_t$ ,  $\theta(B) = 1 - \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ , onde o polinômio  $\theta(B)$  é chamado de operador de média móvel de ordem  $q$ .

Aqui, observa-se que a variável  $X_t$  é explicada a partir por uma média ponderada de  $q$  erros presentes e passados.

Um processo  $MA(q)$  tem FAC finita, no sentido em que ela apresenta um corte após o “lag”  $q$  (Morettin 2006, pág. 122), isto é, possui uma FAC que é zero para defasagens maiores que  $q$ .

Algumas séries temporais podem apresentar, na prática, características de auto-regressividade e de média móvel, de forma simultânea. Para encontrarmos modelos parcimoniosos, com poucos parâmetros, a solução ideal é a modelagem  $ARMA(p,q)$ , representada por

$$(2.13) X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

---

<sup>2</sup> Ruído branco: as v.a.  $\varepsilon_t$  são não-correlacionadas, ou seja,  $Cov(\varepsilon_t, \varepsilon_s) = 0$ ,  $t \neq s$

Na forma polinomial, utilizando os operadores auto-regressivos  $\phi(B)$  e de média móvel  $\theta(B)$ , temos a equação reduzida

$$(2.14) \phi(B) X_t = \theta(B)\varepsilon_t$$

Pressupondo que o processo é estacionário, a função de autocorrelação de um processo ARMA( $p,q$ ) tem FAC infinita em extensão, a qual decai de acordo com exponenciais e/ou senóides amortecidas após o “lag”  $q - p$  (Morettin 2006, pág. 130).

A FAC estimada é útil para identificação de um modelo que supostamente represente o processo formador da série temporal. Porém, Box, Jenkins e Reinsel (1994), citados por Morettin (2006), propõem um outro instrumento para facilitar este procedimento de identificação: a Função de Autocorrelação Parcial (FACP).

As FACP dos processos vistos anteriormente apresentam as seguintes características:

- AR( $p$ ): possui uma FACP zero para defasagens maiores que  $p$ , ou seja  $\phi_{kk} = 0$ , para  $k > p$ ;
- MA( $q$ ): tem uma FACP que se comporta de maneira similar à FAC de um processo AR( $p$ );
- ARMA( $p,q$ ): apresenta FACP que se comporta como a FACP de um processo MA puro.

No caso de séries não-estacionárias, que contêm componentes de tendência ou de sazonalidade, o modelo sugerido é o ARIMA ( $p,d,q$ ).

Assim, dada uma série não-sazonal e não-estacionária, um modelo ARIMA( $p, d,q$ ) é representado por

$$(2.16) \phi(B) (1 - B)^d X_t = \theta(B)\varepsilon_t,$$

onde

$$(2.17) \phi(B) = 1 - \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p$$

$$(2.18) \theta(B) = 1 - \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q,$$

Uma série com tendência, onde a média não é constante, pode ser transformada a fim de adquirir a estacionariedade. Uma das formas é pegar a sua primeira diferença, que é representada por:  $\Delta X_t = X_t - X_{t-1} = (1 - B)^d X_t$ . A segunda diferença é dada por  $\Delta^2 X_t = (1 - B)^2 X_t$ . Geralmente, o valor especificado para  $d$  é pequeno, sendo bastante  $d = 1$  e excepcionalmente  $d = 2$ . Séries que se tornam estacionárias tomando-se um número finito de diferenças,  $d$ , são chamadas não-estacionárias homogêneas, ou ainda, são portadores de raízes unitárias (Morettin, 2006).

A nova série, agora transformada, é dada por:

$$(2.19) W_t = \Delta^d X_t$$

A estratégia para construção do modelo ARIMA envolve três etapas: identificação do modelo, estimação dos parâmetros e diagnóstico ou de verificação. Tais etapas compõem o chamado ciclo iterativo, as quais são detalhadas na seqüência:

#### **a) identificação:**

É o processo mais crítico do ciclo iterativo, pois, não raro, analistas distintos identificam modelos diferentes para uma mesma série temporal, além do que exige a utilização de programas computacionais adequados.

Consiste a identificação em determinar os valores de  $p, d, q$ , do modelo ARIMA( $p, d, q$ ). Para tanto, a etapa de identificação segue os passos:

- verificar se a série é estacionária (média e variância constantes ao longo do tempo), o que pode ser realizado através do auxílio de gráfico. A análise da FAC permite identificar se a série apresenta tendência ou não, pois uma função de autocorrelação onde os coeficientes de correlação decaem para zero de modo relativamente lento sinaliza que a série é não-estacionária;

- caso a série não seja estacionária, a mesma deve ser transformada, utilizando-se tantas diferenças quanto forem necessárias para torná-la estacionária;

- identificar o modelo  $ARIMA(p,d,q)$  através da análise das FAC e FACP, que devem imitar os comportamentos das respectivas quantidades teóricas. A Tabela 7 apresenta o comportamento das funções de autocorrelação e autocorrelação parcial de três modelos ARIMA.

No caso da série apresentar apenas a componente tendência (não sazonal), uma função de autocorrelação persistente em defasagens altas, isto é, com decaimento lento, indica não estacionaridade, necessitando portanto ser diferenciada.

Um instrumento útil para a identificação do modelo apropriado é o correlograma. Através de sua análise e da comparação com o comportamento teórico das autocorrelações de modelos AR, MA e ARMA é possível se identificar o modelo adequado. Por exemplo: um correlograma onde a FAC decai exponencialmente e a FACP é zero para defasagens superiores a  $q$ , indica um modelo  $AR(1)$  para a série, haja vista que o seu coeficiente de autocorrelação teórico tem este comportamento.

Como dito anteriormente, a tarefa de identificar o modelo é complicada, pois vários modelos podem ser julgados como adequados à série, levando em conta apenas o correlograma. Dessa forma, para selecionar a especificação do modelo de forma mais rigorosa, a literatura sugere a utilização dos chamados critérios de informação que levam em conta não apenas a qualidade do ajuste mas também penalizam a inclusão de parâmetros extras (Ehlers 2003, pág.48). Neste trabalho foi utilizado o Critério de Informação de Schwarz – SIC<sup>3</sup>, também conhecido por Critério de Informação Bayesiano, que auxilia na seleção de modelos ao mesmo tempo parcimoniosos no número de variáveis independentes e com bom ajuste, justificando a opção pelo SIC e significância estatística.

O critério de Akaike tem melhor desempenho em pequenas amostras. No entanto, como demonstrado em estudos de Monte Carlo, o AIC

---

<sup>3</sup> Critério de Informação de Schwarz é dado por:  $SIC = -2\ln(ML) + (\text{número de parâmetros})\ln N$ , onde, em modelo  $ARMA(p,q)$ ,  $ML$  é o estimador de máxima verossimilhança da variância residual do modelo e número de parâmetros é dado por  $p+q+1$ .

tende a super-parametrizar os modelos enquanto que o SIC seleciona modelos mais parcimoniosos e é assintoticamente consistente (Enders 2004, pag. 207)

### **b) estimação**

Identificado o modelo provisório ARIMA para a série temporal na forma

$$(2.20) \phi(B) (1 - B)^d X_t = \theta(B)\varepsilon_t$$

o próximo passo é estimar os parâmetros autoregressivos ( $\phi_1 + \phi_2 + \dots + \phi_p$ ) e de média móvel ( $\theta_1 + \theta_2 + \dots + \theta_q$ ), para tanto um dos métodos a ser empregado é o da máxima verossimilhança (EMV). Supondo que o processo  $\varepsilon_t$  é normal, ou seja, para cada  $t$ ,  $\varepsilon_t \sim N(0, \sigma^2)$ , nestas condições os EMV serão aproximadamente estimadores de mínimos quadrados (EMQ) (Morettin, 2006).

### **c) verificação ou diagnóstico**

Feita a identificação e a estimação do modelo, a próxima etapa é verificar se ele representa ou não de forma adequada à série temporal. Caso não seja adequado, reinicia-se o ciclo iterativo a partir da identificação, em busca de um modelo alternativo.

O processo de verificação passa pela análise dos resíduos (erros  $\varepsilon_t$ ). Supondo que o modelo ajustado seja

$$(2.21) \phi(B) W_t = \theta(B)\varepsilon_t$$

Com

$$(2.22) W_t = \Delta^d X_t$$

se este modelo for verdadeiro, então os erros verdadeiros  $\varepsilon_t = \theta^{-1}(B)\phi(B)W_t$  constituirão um *ruído branco* (Morettin, 2006). Se o modelo tiver um bom

ajuste, espera-se que os resíduos se distribuam aleatoriamente em torno de zero com variância aproximadamente constante e sejam não correlacionados (Ehlers, 2005).

Como os resíduos são ordenados no tempo, pode-se tratá-los como uma série temporal. Assim, através das análises do gráfico e do correlograma, é possível verificar se o modelo é adequado para representar o comportamento da série temporal original.

Outra forma para se diagnosticar o ajuste do modelo à série, é utilizando a estatística Q, onde se testa se um grupo de autocorrelações dos resíduos estimados são estatisticamente diferentes de zero.

Utiliza-se com freqüência o teste de Box-Pierce, onde a estatística de teste Q é dada por:

$$(2.24) \quad Q = (T - d) \sum_{k=1}^k \hat{r}_k^2$$

onde,

T = número de observações da série temporal

d = número de diferenças para tornar a série estacionária

K = número de defasagens checadas (10 a 15 primeiras autocorrelações)

$\hat{r}$  = função de autocorrelação do k-ésimo termo residual.

Por sua vez, a autocorrelação dos resíduos é dada por:

$$(2.25) \quad \hat{r}_k = \frac{\sum_t \hat{\epsilon}_t \hat{\epsilon}_{t-k}}{\sum_t \hat{\epsilon}_t^2}$$

O modelo especificado será considerado inadequado, quando o Q calculado for maior que o valor teórico correspondente da distribuição qui-quadrado com  $(k-p-q)$  graus de liberdade, situação em que pelo menos uma as correlações dos resíduos é diferente de zero, ou seja, a hipótese de ruído branco é rejeitada. Neste caso, deve-se buscar um modelo alternativo.

## 2.4. Previsão com modelos ARIMA.

A finalidade deste trabalho é prever a arrecadação do ICMS, no caso para o estado do Piauí. Para tanto, foi revisada a literatura acerca da análise de séries temporais, passando pelo estudo dos vários modelos estocásticos que podem especificar o processo formador da série. Também, foram demonstradas as etapas do ciclo iterativo – identificação, especificação e verificação - do modelo ARIMA. Todo esse processo tem por fim a utilização do modelo identificado e especificado para fazer previsão.

Aqui, o objetivo é prever um valor  $X_{t+h}$ ,  $h > 1$ , partindo do pressuposto que  $X_{t-1}$ ,  $X_{t-2}$ , ...  $X_t$  até o instante  $t$  são conhecidos, onde  $h$  é o horizonte e  $t$  é a origem da previsão. Assim,  $\hat{X}_t(h)$  é a previsão de origem  $t$  e horizonte  $h$ .

Para Ehlers(2005, pág. 37), a previsão de  $X_{t+h}$ , ou seja,  $\hat{X}_t(h)$  é definida como a esperança condicional de  $X_{t+h}$  dados os valores passados, isto é

(2.26)  $\hat{X}_t(h) = E(X_{t+h} / X_t, X_{t-1}, X_{t-2}, \dots)$ , onde a função acima é chamada de função de previsão.

Por se tratar de série temporal, os valores passados de  $X_t$  são conhecidos, assim é comum efetuar a previsão dentro da própria amostra e comparar com o valor observado, de tal forma que a diferença entre o valor previsto e o valor observado é o erro da previsão e pode ser definido por

(2.27)  $\varepsilon_{t+h} = X_{t+h} - \hat{X}_t(h)$ , onde  $\varepsilon_{t+h}$  é o erro de previsão  $h$  passos à frente.

A previsão de  $X_t$ , para um horizonte  $h$  é realizada de tal forma que seja minimizado o erro quadrático médio (EQM). Assim o EQM mínimo é dado por

$$(2.28) \hat{X}_t(h) = \psi_h \varepsilon_t + \psi_{h+1} \varepsilon_{t-1} + \dots = \sum_{j=0}^{\infty} \psi_{h+j} \varepsilon_{t-j}$$

As previsões para  $h$  passos à frente é dada por

$$(2.29) \quad \hat{X}_t(h) = \phi \hat{X}_t(h-1) + \dots + \phi \hat{X}_t(h) + \phi_p X_{t-p+h} - \theta_1 \hat{\varepsilon}_{t-1} - \dots - \theta_q \hat{\varepsilon}_{t-q+h}$$

## 2.5. Função de Transferência

Os métodos de previsão até então estudados são modelos univariados, onde os valores passados da própria variável explicam o seu comportamento futuro. No entanto, para previsão de longo prazo, onde as condições futuras podem se alterar, esses modelos apresentam deficiências.

Uma técnica utilizada para melhorar o poder preditivo de longo prazo consiste em usar a função de transferência, que é utilizada quando se deseja explicar o comportamento de uma série temporal a partir de uma outra série ordenada no tempo, com a qual que tem relação de causalidade, ou seja, existe uma relação linear entre as séries. O objetivo é aumentar o grau de acurácia da previsão, por meio da inclusão de informações não contempladas na série da variável em análise, através da inserção de outras variáveis explicativas.

Para Ferreira (1996, pág. 34), “a principal vantagem da função de transferência consiste na possibilidade de se aprimorar as previsões em relação aos modelos ARIMA, principalmente quando tais previsões forem realizadas para um período que extrapole o curto prazo. A maior desvantagem desse modelo está na dificuldade prática de disponibilidade de dados que sirvam como variável explicativa”.

Supondo o modelo de duas variáveis  $(X_t, Y_t)$ ,  $t = 0, 1, 2, \dots$ , não necessariamente estacionário, mas que, por meio de diferenças sucessivas, tornam a série original estacionária  $(x_t, y_t)$ . A estruturação do modelo tem por base a suposição de existência de uma relação de causalidade entre as séries  $x_t$  e  $y_t$ . Assim, o objetivo da metodologia é identificar uma função  $v(t)$ , denominada de função de transferência, tal que

$$(2.30) \quad y_t = v(B) x_t + N_t$$

onde  $N_t$  é um processo estacionário ARMA  $(p, q)$ , isto é,  $\phi(B).N_t = \theta(B)\varepsilon_t$ , e  $\varepsilon_t$  é um ruído branco, independente de  $x_t$ .

A identificação do modelo função de transferência envolve dois estágios. No primeiro estágio, ajustam-se modelos ARMA univariados para cada série do modelo; num segundo estágio, identifica-se um modelo dinâmico para as séries e resíduos. Neste trabalho, utilizou-se, também, para identificação e especificação do modelo o SIC. Por fim, combinam-se os modelos obtidos nos dois estágios para identificar um modelo dinâmico para as duas séries originais (Toloi 2003, pág. 3).

A adequação do modelo é verificada através da análise da função de autocorrelação e da função de autocorrelação parcial dos resíduos do modelo identificado, tal qual no modelo ARIMA. Se o modelo for adequado, espera-se que os resíduos se distribuam aleatoriamente em torno de zero com variância aproximadamente constante e sejam não correlacionados, ou seja, é um ruído branco.

## 2.6. Combinação de Previsões.

A combinação de previsões tem por objetivo aumentar a performance dos prognósticos, em decorrência da complementaridade das informações contidas nas previsões individuais, ou de outra forma, reduzir a incerteza associada a um modelo de previsão individual. Nesta técnica, a idéia é conjugar informações de vários modelos de previsões em torno de um modelo de combinação de previsões, que, conforme demonstrado empiricamente, apresentam melhores resultados preditivos que previsões realizadas de forma individual.

O valor previsto da variável em estudo derivado da combinação é formado a partir de várias informações, o que dá mais robustez à previsão na medida em que incluem mais variáveis e informações especificadas por outros

modelos. Além do que, a diversificação dos modelos, leva a diminuição das deficiências contidas em um modelo individual.

Há várias formas de combinação de previsões, que se estendem desde a média aritmética ou ponderada até a utilização de pesos adaptativos segundo a performance preditiva passada. Nestes últimos, o peso de cada previsão está associado ao seu grau de previsão passado.

Tem-se tornado popular a escolha de ponderações através da regressão dos valores previstos por cada modelo nos valores reais da variável escolhida como alvo da previsão. Obviamente esta regressão deve ser processada num período utilizado para estimação dos modelos. Em geral isto acarreta dois problemas adicionais para o pesquisador: um é a necessidade de um número razoável de dados, o que nem sempre é regra em dados de variáveis econômicas; o segundo refere-se à necessidade da eliminação da multicolinearidade, normalmente presente em regressões desta natureza.

Com o propósito de evitar estes problemas utiliza-se neste estudo um critério simples que pondera as previsões individuais com base no desempenho, avaliado por uma outra medida a qual denominaremos de Fator de Combinação. A fórmula do  $FC$  é descrita da seguinte forma:

$$(2.31) FC_j = \left( \frac{1}{EPM_j} \right) \times \frac{1}{\sigma_{\varepsilon_j} / \frac{\sum ICMS_i}{m}}$$

onde  $EPM_j$  é o erro percentual médio no período de previsão do modelo  $j$  e  $\sigma_j$ , o desvio padrão do seu erro médio.

Determinado os valores de  $FC$ , parte-se então para etapa da determinação dos ponderadores que compõem o modelo combinado. No caso de dois modelos para o ICMS, modelo A e B, após a previsão para um período ex-post, calcula-se os seguintes  $FC$ .

$$(2.32) FC_A = \left( \frac{1}{EPM_A} \right) \times \frac{1}{\sigma_{\varepsilon_A} / \frac{\sum ICMS_i}{m}}$$

$$(2.33) FC_B = \left( \frac{1}{EPM_B} \right) \times \frac{1}{\sigma_{\varepsilon_B} / \frac{\sum ICMS_i}{m}}$$

Em seguida podemos obter as ponderações  $P_A$  e  $P_B$  através das equações acima.

$$(2.34) P_A = \frac{FC_A}{FC_A + FC_B}$$

$$(2.35) P_B = \frac{FC_B}{FC_A + FC_B}$$

Calculada as ponderações, as previsões são encontradas através da ponderação simples dos valores previstos pelo modelo A e B. Matematicamente:

$$(2.36) PICMS_{t+1}^{comb} = P_A PICMS_{t+1}^A + P_B PICMS_{t+1}^B$$

## 2.7. Métodos de Performance Preditiva

Quando o objetivo da análise da série temporal é o de realizar previsão, após especificado o modelo, uma inquietação natural é saber se o modelo é adequado e o quanto o seu poder preditivo é bom. Para isso, vários métodos são sugeridos na literatura, os quais utilizam comumente os erros de previsão,  $\varepsilon_{t+h} = X_{t+h} - \hat{X}_t(h)$ , em seus cálculos.

O método erro médio (EM) é definido como a média dos erros de previsão e é representado por

$$(2.37) EM = \frac{\sum_{t=1}^n (X_t - \hat{X}_t)}{n}$$

onde  $X_t$  é o valor observado (real) e  $\hat{X}_t$  é o valor estimado para  $h$  períodos à frente.

O erro absoluto médio (EAM) é outro método sugerido, o qual pode ser utilizado quanto é possível se ignorar alguns erros elevados e é definido por

$$(2.38) \text{ EAM} = \frac{\sum_{t=1}^n |X_t - \hat{X}|}{n}$$

Quando erros elevados são inaceitáveis, o método sugerido é o erro quadrático médio (EQM), o qual penaliza os erros grandes, elevando-o ao quadrado. Esse método é representado por

$$(2.39) \text{ EQM} = \frac{\sum (X_t - \hat{X})^2}{n}$$

O método erro percentual absoluto médio (EPAM) leva em consideração o erro relativo de cada previsão em relação aos valores observados da série e é representado por

$$(2.40) \text{ EPAM} = \frac{\sum_{t=1}^n \frac{|X_t - \hat{X}_t|}{X_t}}{n}$$

Neste trabalho, optou-se por usar o EPAM por ser uma medida muito utilizada em estudos da espécie, o que possibilita a comparação do desempenho dos modelos especificados por este trabalho com outros já realizados.

### 3. ANÁLISE DOS RESULTADOS

Neste capítulo serão apresentados os resultados encontrados na estimação dos modelos e na previsão do ICMS no estado do Piauí. Para tanto, a partir dos modelos descritos no capítulo anterior, realizaram-se várias simulações<sup>4</sup>, utilizando como base os dados, em valores reais, das séries temporais relacionadas abaixo, referente ao período de 1996 a 2006, portanto uma amostra de 132 meses:

- Arrecadação mensal do ICMS – ICMSR;
- Fundo de participação dos Estados – FPER; e
- Consumo de Cimento mensal em toneladas – CONCIM.

Primeiramente, realizou-se o teste de raiz unitária para as variáveis empregadas nos modelos. Na seqüência, estimou-se o modelo ARIMA, tendo sido utilizado a série ICMSR. Já para estimação da Função de Transferência, foram utilizadas as séries FPER e CONCIM, pelos motivos que serão informados adiante. Nesta etapa, todas as séries usadas se referiam ao período de janeiro de 1996 a junho de 2006, ficando reservado o período de julho/06 a dezembro/06, para a realização das previsões *ex-post*.

Num segundo momento, após procedimentos estatísticos que demonstraram a adequabilidade dos modelos à série, obteve-se a previsão para o imposto, a partir dos modelos estimados. Utilizando o período reservado para a previsão *ex-post*, compararam-se os resultados obtidos e foram aferidos os erros das previsões, usando como medidor da acurácia o EPAM, detalhado na fórmula 2.40.

Por fim, combinaram-se os resultados das previsões dois modelos identificados, de forma que foi encontrada uma terceira previsão, bem como uma nova série de valores previstos. Assim, é apresentado na seqüência, o resultado das três previsões, que tem por objetivo demonstrar o desempenho

---

<sup>4</sup> Para realização das simulações, estimação e previsão, foi utilizado o aplicativo Eviews 4.2

de cada uma, bem como a de possibilitar a escolha daquela que ofereça a melhor performance preditiva.

### **3.1 Ajustes nas Séries.**

No desenvolvimento do trabalho, as séries coletadas sofreram ajustes. No caso da série arrecadação do ICMS, efetuou-se ajustes na mesma de forma a retirar o efeito de algumas especificidades.

Primeiro, expurgou-se o efeito da Anistia (item 1.3. Tabela 5) sobre arrecadação mensal, através da dedução do valor arrecadado por conta daquela renúncia fiscal do total da arrecadação do respectivo mês de referência.

Ainda no tocante aos ajustes na arrecadação, realizaram-se alterações nos valores de 2005, por conta de que, os valores arrecadados, relativos ao segmento da energia elétrica, que representa aproximadamente 13% do total, foram pagos com atraso e apropriados pelo regime caixa, contrário aos demais meses, onde a imputação foi feita pelo regime de competência. Tal procedimento distorceu a arrecadação mensal e conseqüentemente poderia influenciar de forma negativa na acurácia da predição.

Por fim, os valores nominais das séries utilizadas no estudo foram transformados em valores reais, tendo sido utilizado como base 100 o mês de junho de 2006 e como indexador o IGP-DI.


### **3.2 Testes de Raiz Unitária**

Graficamente, como podem ser vistas no Gráfico 2, as séries sinalizavam para a existência de estacionariedade com quebra. No entanto, para complementar a análise da estacionariedade das séries usou-se o teste de Aumentado de Dick-Fuller – ADF.

Dessa forma, todas as séries foram submetidas ao teste para se verificar a existência ou não de raízes unitárias, cujo objetivo era confirmar se as mesmas eram estacionárias ou não. As Tabelas 8 a 13 do anexo revelam

que para todas as séries a hipótese nula (  $H_0$  = tem raiz unitária ) foi rejeitada, logo as séries eram estacionárias.

**Gráfico - 2 – Séries Temporais das Variáveis da Pesquisa –Valores reais**



Fonte: elaborado pelo autor através do aplicativo Eviews

### 3.3 Estimação dos Modelos de Previsão do ICMS mensal

#### 3.3.1 Modelo ARMA

Como a variável ICMSR era estacionária, observou-se que o modelo adequado era o ARMA. Restava então, identificar a ordem  $p$  e  $q$ . A determinação de  $p$  e  $q$  deve ser feita de tal forma que forneçam o melhor ajuste do modelo possível. Os valores ótimos de  $p$  e  $q$  são identificados pelo critério de informação de Schwarz no intervalo  $[0, k_{\max}]$ , onde  $k_{\max} = [4(T/100)^{1/4}]$  é o número máximo de defasagens permitido no modelo e  $T$  é o tamanho da

Amostra<sup>5</sup>. Substituindo o tamanho da amostra (130 observações) utilizada na estimação (jan/96 a jun/06), encontrou-se o  $k_{\max} = 5$ . Estimaram-se os modelos ARMA, variando do número máximo de defasagem 5 até a mínima, tendo sido identificado o modelo ARMA (1, 0) como o mais ajustado. A Tabela 14 do anexo traz os resultados de cada estimação.

Analisando os resíduos gerados pelo modelo, utilizando o correlograma como ferramenta, verificou-se que estes apresentaram o comportamento de um ruído branco, o que denota que não é possível melhorar o modelo e que este pode ser utilizado para gerar previsões. O correlograma pode ser visto na Tabela 16.

O resultado da estimação é apresentado na Tabela 15 e na equação 3.1:

$$(3.1) \quad ICMS_t = 54.886204 + 151.1884.t + 0,443277ICMS_{t-1}$$

$$(24,43680) \quad (4,985399) \quad (5,452945)$$

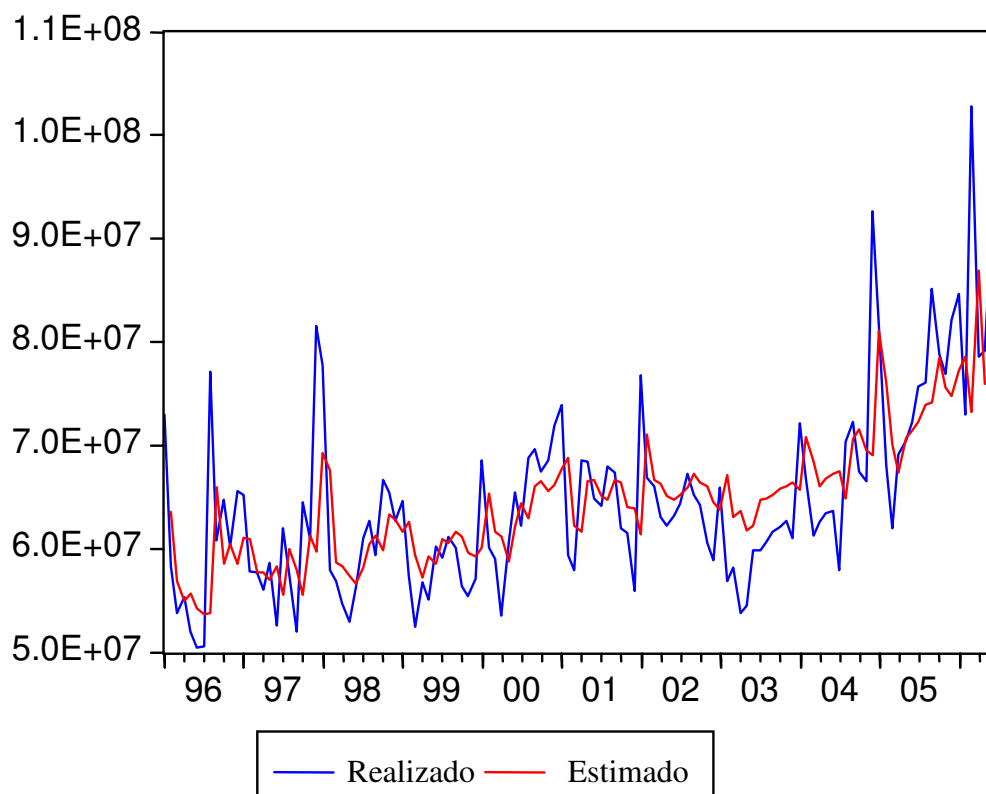
Pela análise da estatística t (valores abaixo dos coeficientes), verifica-se que os coeficientes da equação são todos estatisticamente diferentes de zero, ou seja, são todos significantes ao nível de 5 %.

O Gráfico 3 mostra o ajustamento dos valores estimados à série realizada para o período utilizado na estimação do modelo.

---

<sup>5</sup> Schwert (1989) sugere  $k_{\max} = [d(T/100)^{1/d}]$  e aponta como bons valores d=4 ou d=12. Optou-se por trabalhar com d=4, pois o mesmo autor afirma que o mesmo é mais consistente para pequenas amostras.

**Gráfico - 3 – Valores Realizados e Estimados pelo modelo ARMA –  
Período de Jan/96 a Jun/06.**



Fonte: elaborado pelo autor através do aplicativo Eviews


### 3.2.2 Modelo de Função de Transferência

Na modelagem da função de transferência, as variáveis Consumo de Energia Elétrica, Créditos levantados pela Fiscalização, Consumo de Cimento, Número de fiscalizações e Fundo de Participação do Estado foram testadas. No entanto, as que mais apresentaram um movimento correlacionado com a arrecadação do ICMS foram FPER e CONCIM, razão pela qual foram escolhidas como variáveis independentes para serem utilizadas no modelo. Ainda, pelos levantamentos efetuados junto ao balanço geral do estado, nota-se que o volume de recursos injetados na economia estadual pelo FPE representou, em 2006, 40,39% do total receita corrente do Estado. Tais recursos, exógenos à economia estadual, aumentam a renda interna. Para Rossetti (1997), a teoria econômica descreve que a receita tributária depende

da renda das famílias, logo aumentando a renda do Estado, há um incremento no consumo o que ocasiona um deslocamento no nível da arrecadação.

Para respaldar ainda mais a decisão pelo uso do FPER como variável independente, foi calculado o coeficiente de correlação das variáveis, cujo valor foi de 0,3478, o que informa que as variáveis têm correlação positiva, ou seja, são correlacionadas. Visualmente, este movimento está demonstrado no Gráfico 4,

**Gráfico - 4 – Correlação ICMSR versus FPER – Jan/96 a Dez/06**



Fonte: elaborado pelo autor através do aplicativo Eviews

Na estimação do modelo, utilizou-se o critério de informação de Schwarz. Preliminarmente, estimaram-se vários os modelos contemplando as variáveis ICMSR, FPER e CONCIM, com defasagens variando de 1 a 5, tendo apresentado o melhor resultado, em termos de adequação, o ICMSR com uma defasagem e o FPER e CONCIM em níveis. A Tabela 17 traz o resultado do critério de informação de Schwarz para os modelos.

O resultado da estimativa desta função pode ser visualizado Tabela 18 e na equação 3.2.

(3.2)

$$ICMS_t = 19.532380 + 78.04202 t + 0,403ICMS_{t-1} + 0,099FPER + 246,15CONCIM.$$


$$(3.201289) \quad (4.025181) \quad (4.856500) \quad (2.120679) \quad (2.225125)$$

Pela análise da estatística t (valores abaixo dos coeficientes), observa-se, como no modelo ARMA, que os coeficientes da função de transferência são todos significantes.

No Gráfico 5 pode-se observar o ajustamento da estimativa em relação ao realizado para o período de jan/96 a jun/06.

Verificou-se que o modelo era adequado à série, haja vista que o comportamento dos resíduos dos erros foi de um ruído branco (Tabela 19).

**Gráfico - 5 – Valores Realizados e Estimados pela Função de Transferência – Período de Jan/96 a Jun/06.**



Fonte: elaborado pelo autor através do aplicativo Eviews

### 3.3.3. Previsões

No sentido de atingir o objetivo proposto por esta dissertação, qual seja o de fazer previsão do ICMS, depois de identificados e estimados os modelos e realizadas as previsões através dos modelos comentados acima,

montou-se a Tabela 20, a qual contempla os resultados das previsões para o período e jul/06 a dez/06. Na tabela, o resultado das previsões atingido pelos modelos ARMA é denominado de ARMA e o da Função de Transferência é chamado de FUTR. Uma outra coluna, denominada de VARI, traz informação sobre a razão entre o erro de previsão e o valor realizado.

**Tabela - 20 – Valores Previstos e Realizados do ICMSR Mensal**

Mês	Realizado	ARMA	VARI	FUTR	VARI
07.06	84.815.369,83	81.341.492,91	0,041	82.604.417,40	0,026
08.06	90.144.779,48	78.993.895,54	0,124	81.101.671,14	0,100
09.06	94.956.155,20	81.440.467,87	0,142	82.164.932,63	0,135
10.06	87.998.641,26	83.657.407,91	0,049	84.323.289,81	0,042
11.06	99.551.967,27	80.657.475,44	0,190	83.874.636,43	0,157
12.06	92.774.316,52	85.862.963,79	0,074	90.434.751,69	0,025

Fonte: resultado obtido pelo autor através do aplicativo Eviews.

Utilizando-se o EPAM, verificou-se que o modelo que apresentou melhor desempenho foi a Função de Transferência, cujo erro foi de 8,1 %. A previsão realizada a partir do modelo ARMA apresentou um erro de 10,3 %.

No propósito de melhorar a previsão a partir de informações contidas e não captadas nos modelos individuais, utilizou-se a técnica de combinação de previsões, ocasião em que foram combinadas as previsões geradas pelos modelos ARMA e Função de Transferência. Para a identificação dos pesos, utilizou-se a equação 2.34, a qual possibilitou a estruturação da seguinte equação:

$$(3.3) \quad ICMS_{t+1}^{comb} = 0.43 \text{ ARMA} + 0.57 \text{ FUTR}$$

Nova previsão foi realizada com a utilização da equação acima, ou seja, usando a combinação de previsões. O resultado está demonstrado na Tabela 21, onde a coluna COMB indica o resultado obtido pela técnica de combinação de previsões.

**Tabela - 21 – Valores Previstos e Realizados do ICMSR Mensal**

Mês	Realizado	ARMA	VARI	FUTR	VARI	COMB	VARI
07.06	84.815.369,83	81.341.492,91	0,041	82.604.417,40	0,026	82.059.178,64	0,032
08.06	90.144.779,48	78.993.895,54	0,124	81.101.671,14	0,100	80.191.687,24	0,110
09.06	94.956.155,20	81.440.467,87	0,142	82.164.932,63	0,135	81.852.161,54	0,138
10.06	87.998.641,26	83.657.407,91	0,049	84.323.289,81	0,042	84.035.810,53	0,045
11.06	99.551.967,27	80.657.475,44	0,190	83.874.636,43	0,157	82.485.700,77	0,171
12.06	92.774.316,52	85.862.963,79	0,074	90.434.751,69	0,025	88.460.986,84	0,046

Fonte: resultado obtido pelo autor através do aplicativo Eviews

Verificou-se a Combinação de Previsões apresentou EPAM de 9,1 %, bem como todos os resultados foram bastante superiores a outros resultados obtidos com trabalhos semelhantes, razão pela qual os modelos foram reestimados

### 3.4. Reestimação dos Modelos de Previsão da Arrecadação do ICMS mensal

Além do motivo acima, os modelos especificados no item 3.3. apresentaram valores sempre abaixo dos valores realizados, indicando que os modelos não estavam bem ajustados para a realização de previsão. Dessa forma todos os modelos foram reestimados com a inclusão de uma variável qualitativa “Djan03”, cujo objetivo era captar o efeito de uma possível mudança estrutural causado na série a partir de janeiro 2003.

Os prováveis motivos para a mudança estrutural teria sido a alteração realizada na legislação tributária que majorou a carga tributária sobre algumas mercadorias (cigarro, fogos, energia elétrica, etc.), a inclusão de novos produtos na sistemática de pagamento antecipado do ICMS (substituição tributária), bem como o fortalecimento da fiscalização de trânsito e de empresas.

Todos os procedimentos anteriores foram repetidos, desta vez com a inclusão da variável “Djan03”, tendo se constado o seguinte:

#### 3.4.1. Modelo ARMA:

Utilizando-se o critério de informação de Schwarz (Tabela 22), o modelo que melhor se ajustou a série foi o ARMA (2,3) como pode ser visto na Tabela 23 e na equação 3.4.

(3.4)

$$ICMS_t = 58.004412 - 63.145898D_t + 88.71218.t + 623.69340DT_t + 0,874ICMS_{t-1} - 0,072ICMS_{t-1} - 0,762\varepsilon_{t-1} - 0,249\varepsilon_{t-2} - 0,108\varepsilon_{t-3}$$

onde

$$D_t = \begin{cases} 1 & \text{se } t \geq T_B \\ 0 & \text{se } t < T_B \end{cases},$$

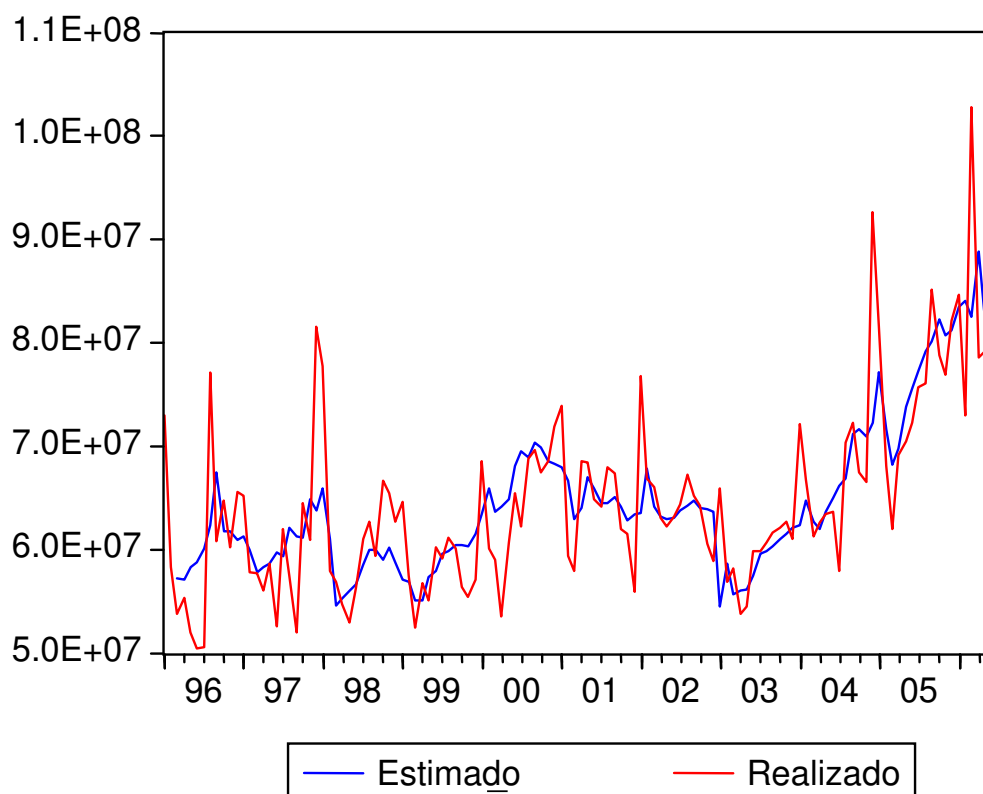
$$DT_t = \begin{cases} (t+1) - T_B & \text{se } t \geq T_B \\ 0 & \text{se } t < T_B \end{cases},$$

$T_B$  é o ponto no tempo correspondente a janeiro de 2003.

Observa-se que os coeficientes dos termos AR (2), MA(2) e MA(3) são estatisticamente insignificantes ao nível de 5%.

O Gráfico 6 apresenta o ajustamento dos valores estimados pelo modelo ARMA(2,3) aos valores realizados, no período de jan/96 a jun/06

**Gráfico - 6 – Valores Realizados e Estimados – Modelo ARMA (2,3)**  
**Período; Jan/96 a Dez/06**



Fonte: elaborado pelo autor através do aplicativo Eviews

### 3.4.2. Modelo Função de Transferência

O SIC (Tabela 24) informa que o modelo de Função de Transferência mais adequado é o ICMSR defasado em um período e o FPER e CONCIM em nível.

O resultado da reestimação do modelo pode ser visto na Tabela 25 e na equação 3.5.

(3.5)

$$ICMS_t = 37.263.411 - 44.383.080D_t + 50.613.911t + 455.459,40DT_t + 0,207ICMS_{t-1} + 0,061FPER_t + 186.3375CONCIM_t,$$

onde

$$D_t = \begin{cases} 1 & \text{se } t \geq T_B \\ 0 & \text{se } t < T_B \end{cases},$$


$$DT_t = \begin{cases} (t+1) - T_B & \text{se } t \geq T_B \\ 0 & \text{se } t < T_B \end{cases},$$

$T_B$  é o ponto no tempo correspondente a janeiro de 2003.

Observando-se a Tabela 25, nota-se que os coeficientes das variáveis Tempo, FPER e CONCIM não são estatisticamente diferentes de zero.

No Gráfico 7 está demonstrado o ajustamento dos valores estimados pelo modelo Função de Transferência aos valores realizados, no período de jan/96 a dez/06.

**Gráfico - 7 – Valores Realizados e Estimados – Modelo Função de Transferência - Período: Jan/96 a Dez/06**



Fonte: elaborado pelo autor através do aplicativo Eviews

### 3.4.3. Previsões

A partir dos modelos estimados, realizaram-se previsões ex-post para o período de jul/06 a dez/06, cujos valores estimados estão dispostos na Tabela 26

**Tabela - 26 – Valores Previstos e Realizados do ICMSR Mensal**

Mês	Realizado	ARMA	VARI	FUTR	VARI
07.06	84.815.369,83	87,454,680.50	-0.031	87,184,534.90	-0.028
08.06	90.144.779,48	85,880,050.74	0.047	87,022,838.98	0.035
09.06	94.956.155,20	87,064,052.19	0.083	87,849,447.95	0.075
10.06	87.998.641,26	87,550,946.83	0.005	89,583,635.00	-0.018
11.06	99.551.967,27	85,289,909.50	0.143	90,122,664.55	0.095
12.06	92.774.316,52	86,960,879.72	0.063	94,107,870.42	-0.014

Fonte: resultado obtido pelo autor através do aplicativo Eviews

Aqui, utilizando-se o EPAM para medir a acurácia, verificou-se que o modelo que apresentou melhor desempenho foi a Função de Transferência, cujo erro foi de 4,4 %. A previsão realizada a partir do modelo ARMA apresentou um erro de 6,2 %.

Na seqüência e dentro do propósito da dissertação, foram combinadas as previsões geradas pelos modelos ARMA e Função de Transferência. Para a identificação dos pesos, utilizou-se a equação 2.34, a qual possibilitou a estruturação da equação 3.6.

$$(3.6) \text{ICMS}_{t+1}^{\text{comb}} = 0,281\text{ARMA} + 0,719\text{FUTR}$$

Através da combinação de previsões os resultados estimados constantes da Tabela 27, para o período de jul/06 a dez/06, apresentaram EPAM de 3,2%.

**Tabela - 27 – Valores Previstos e Realizados do ICMSR Mensal**

Mês	Realizado	ARMA	VARI	FUTR	VARI	COMB	VARI
07.06	84.815.369,83	87,454,680.50	0.031	87,184,534.90	-0.028	87,260,600.00	-0.029
08.06	90.144.779,48	85,880,050.74	0.047	87,022,838.98	0.035	86,701,063.25	0.038
09.06	94.956.155,20	87,064,052.19	0.083	87,849,447.95	0.075	87,628,303.49	0.077
10.06	87.998.641,26	87,550,946.83	0.005	89,583,635.00	-0.018	89,011,289.49	-0.012
11.06	99.551.967,27	85,289,909.50	0.143	90,122,664.55	0.095	88,761,902.13	0.108
12.06	92.774.316,52	86,960,879.72	0.063	94,107,870.42	-0.014	92,095,486.96	0.007

Fonte: resultado obtido pelo autor através do aplicativo Eviews

Dessa forma, verifica-se que a inclusão da variável *dummy* com o objetivo de captar o efeito causado na estrutura da série, a partir de janeiro de 2003, possibilitou uma performance melhor na capacidade preditiva dos modelos.

Verificou-se que o modelo Função de Transferência, talvez por incluir variáveis explicativas que retratam a atividade econômica estadual e por isso descreva melhor a dinâmica da arrecadação do ICMS no estado, manteve-se com o melhor desempenho de previsão com EPAM de 4,4%, sendo seguido pelos modelos Combinação de Previsões com EPAM de 4,5% e ARMA com de 6,2%.

Os resultados obtidos através dos três modelos utilizados no trabalho foram comparados com o resultado do modelo atualmente utilizado pela Secretaria da Fazenda do Piauí, a qual utiliza a equação 3.7 para realizar previsão.

$$3.7. ICMS_{t,i} = (1 + \beta_i \cdot \check{Y}) \cdot (1 + \check{y}_i \cdot \acute{\omega}) \cdot ICMS_{t-1,i} \cdot X,$$

onde:

$\beta_i$  = Resposta/elasticidade da arrecadação de ICMS a uma variação de 1% no PIB do setor i;

$\check{Y}$  = Taxas previstas de variação do PIB para o ano no setor i;

$\check{y}_i$  = Resposta/elasticidade da arrecadação do ICMS a uma variação de 1% no preço relativo do setor i, ao ano;

$\acute{\omega}$  = Taxas previstas de variação no preço relativo do setor i, ao ano; e

X = Taxas de incremento da arrecadação por inovações tecnológicas e esforços fiscais adicionais, definidas pelos gestores da SEFAZ-PI.

A coluna SEFAZ da Tabela 28 refere-se aos valores previstos pelo método atualmente utilizado pela Secretaria da Fazenda e a última coluna chamada de VARI informa sobre a razão entre o erro de previsão e o valor realizado pelo referido método.

**Tabela - 28 – Valores Previstos e Realizados do ICMSR Mensal, incluindo método SEFAZ**

Em mil

Mês	Realizado	ARMA	VARI	FUTR	VARI	COMB	VARI	SEFAZ	VARI
07.06	84.815,3	87,454,6	0.031	87,184,5	-0.028	87,260,6	-0.029	85,742,0	-0.01
08.06	90.144,7	85,880,0	0.047	87,022,8	0.035	86,701,0	0.038	85,538,0	0.05
09.06	94.956,1	87,064,0	0.083	87,849,4	0.075	87,628,3	0.077	101,248,0	-0.07
10.06	87.998,6	87,550,9	0.005	89,583,6	-0.018	89,011,2	-0.012	94,645,0	-0.08
11.06	99.551,9	85,289,9	0.143	90,122,6	0.095	88,761,9	0.108	90,082,0	0.10
12.06	92.774,3	86,960,8	0.063	94,107,8	-0.014	92,095,4	0.007	97,382,0	-0.05

Fonte: resultado obtido pelo autor através do aplicativo Eviews

Calculando-se a medida de acurácia do modelo utilizado pela SEFAZ, verifica-se que o EPAM é de 6,00%, portanto superior aos modelos Função de

Transferência (EPAM de 4,4%) e Combinação de Modelos (EPAM de 4,5%), porém inferior ao ARMA (EPAM de 6,2%).

## CONCLUSÃO

Inegável é a importância do ICMS para a economia dos estados, principalmente para o estado do Piauí, onde o valor arrecadado com o tributo corresponde a 31,66% da receita corrente líquida. Dessa forma, o comportamento de sua arrecadação é motivo de preocupação para o gestor público. Afinal, uma queda inesperada em seu montante, compromete a capacidade de pagamento do erário.

Diante disso, é que esta dissertação teve por objetivo a modelagem de um modelo para previsão de arrecadação do imposto, baseado nas técnicas mais utilizadas por outros pesquisadores do tema.

No trabalho, optou-se pela Análise de Séries Temporais para a previsão do ICMS, e dentre as várias técnicas utilizaram-se os modelos ARMA, Função de Transferência e Combinação de Previsões.

Na execução da dissertação, realizou-se, no capítulo 1, uma análise do comportamento do ICMS na economia estadual, bem como comentários sobre os aspectos material, temporal, subjetivo e quantitativo do imposto. No capítulo 2, teceram-se comentários sobre a teoria que dá suporte aos modelos utilizados para se realizar previsões e sobre o modo de apurar o desempenho de cada modelo.

O capítulo 3 foi reservado para a análise dos resultados empíricos da pesquisa. Aqui, num primeiro momento, verificou-se que, para a amostra pesquisada, o modelo que apresentou o melhor resultado na realização da previsão do ICMS para o estado do Piauí, foi o modelo da Função de Transferência com EPAM de 8,1%, seguido do modelo Combinação de Previsões com EPAM de 9,1% e do modelo ARMA com EPAM 10,3%.

Diante dos baixos desempenhos observados na predição, resolveu-se incluir uma variável qualitativa nas estimações dos modelos. O objetivo era captar o efeito provocado na estrutura da série ICMSR, a partir do ano de 2003, motivado pelas medidas adotadas pela Secretaria da Fazenda no sentido de aumentar a arrecadação do imposto.

Verificou-se, então, que, após a reestimação dos modelos com a inclusão da variável “DJan03”, a acurácia da previsão melhorou. No entanto, o modelo Função de Transferência continuou como o modelo mais ajustado com

EPAM de 4,4%, sendo seguido pelos modelos Combinação de Previsões com EPAM de 4,5% e ARMA(2,3) com EPAM de 6,2%.

O trabalho possibilitou realizar uma comparação com o modelo atualmente utilizado pela SEFAZ, momento em que se verificou que os modelos Função de Transferência e Combinação de Previsões apresentaram melhores resultados em termo de acerto.

Observa-se que o modelo adotado pela Secretaria, aparentemente simples, exige boas previsões para a taxa de variação do PIB e de preço dos setores, bem como para as elasticidades PIB da arrecadação de ICMS e preço do setor arrecadação do ICMS. No mesmo sentido, o modelo, na fixação da variável “taxas de incremento da arrecadação por inovações tecnológicas e esforços fiscais adicionais”, depende do subjetivismo de especialistas, o que o torna muito vulnerável, haja vista que a acurácia do modelo exige muito conhecimento das pessoas responsáveis pela administração tributária.

Ressalte-se que as séries analisadas, dentro do período da amostra, mantiveram-se estacionárias conforme demonstrado no teste de raiz unitária, tampouco apresentaram sazonalidades, porém esse comportamento pode se modificar quando utilizado outro período.

Ressalte-se, ainda, que as previsões realizadas no presente trabalho foram efetuadas a partir de valores já realizados, portanto ex-post. O mesmo desempenho dos modelos propostos pode não ser observado para previsões fora da amostra, pois as variáveis da Função de Transferência terão que ser estimadas. Dessa forma, recomenda-se que o trabalho seja complementado com previsões ex-ante, o que poderá confirmar a performance dos modelos.

Por fim, verificou-se que os modelos estimados nesta dissertação apresentaram resultados tão bons ou melhores que outros trabalhos desenvolvidos sobre o tema, o que vem ratificar a importância dos modelos que utilizam a análise das séries temporais para a realização de previsão.

**REFERÊNCIAS BIBLIOGRÁFICAS:**

- ARAÚJO, Inaldo da Paixão Santos e ARRUDA, Daniel Gomes. **Contabilidade Pública: da teoria à prática**. São Paulo: Saraiva, 2006.
- BUNN, Derek. **Forecasting With More Than One Model**. London Business School, UK. Journal of Forecasting, vol. 8, 161-166. 1989.
- CARRAZZA, Roque Antônio. **ICMS**. 11<sup>a</sup> ed. São Paulo: Malheiros Editores, 2006.
- CLOWER, L. Terry; WEINSTEIN, Bernard L.; THARP, Ryan. **Sales Tax Revenue In The City Of Arlington, Texas: Historical Review and Projections**. Center for Economic Development and Research. University of North Texas. Denton, Texas. January, 2006.
- CORVALÃO, Eder Daniel. **Previsão da Arrecadação do Imposto sobre Circulação de mercadorias e Serviços em Santa Catarina: Aplicação da Abordagem geral para o Específico em Modelos Dinâmicos**. Universidade Federal de Santa Catarina, Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção, 2002.
- EHLERS, R.S. **Análise de Séries Temporais**. Departamento de Estatística, UFPR. Disponível em <http://www.est.ufpr.br/~ehlers/notas>. Acesso em: 10.03.2007.
- ENDERS, Water. **“Applied Econometric Time Series”**. Wiley Series in Probability and Mathematical Statistics. 1st. edition.
- FERREIRA, Roberto Tatiwa. **Modelos de Análise de Séries Temporais Para Previsão Do ICMS Mensal do Ceará**. Universidade Federal do Ceará, Dissertação de Mestrado submetida ao Programa de Pós-graduação em Economia, 1996.
- GRANGER, C. W.J. **Invited Review Combining Forecast-Twenty Years Later**. Journal of Forecasting, vol. 8, 167-173. 1989.
- HILL, R. Carter et.al. – **Econometria**. 2 ed. São Paulo: Saraiva, 2003.
- ICHIARA, Yoshiaki. **Direito Tributário**. 9<sup>a</sup> ed. São Paulo: Atlas, 2000.
- Lei Complementar 101, de 04 de maio de 2000 – **Lei de Responsabilidade Fiscal**. Artigos 11 e 12. União.
- Lei Complementar n° 028, de 09 de junho de 2003. **Lei Orgânica da Administração Pública do Estado do Piauí**. Artigo 30. Piauí.
- MACHADO, Hugo de Brito. **Curso de Direito Tributário**. 25 ed. São Paulo: Malheiros, 2004.

MELO, Bruno Stephan Veras de. **Modelo de Previsão para Arrecadação Tributária.** Monografia vencedora em 1º lugar no VI Prêmio Tesouro Nacional – 2001. Orçamentos e Sistemas de Informação sobre a Administração Financeira Pública, Brasília : ESAF, 2001.

- MONTORO FILHO, André franco e et al. **Manual de Economia;** organizadores Diva Benevides Pinho, Marco Antônio Sandoval de Vasconcelos. 3 ed. São Paulo:Saraiva, 2002.

- Morettin, Pedro A. e Célia M.C.Toloi – **Análises de Séries Temporais.** 2 ed. rev. e ampl. São Paulo: Edgard Blucher, 2006.

- PECEGUINI, Edílson Eugênio. **Análise Comparativa de Métodos de Previsão Aplicados a Arrecadação do ICMS – Estado de São Paulo.** Monografia Premiada pelo Tesouro Nacional-2º Lugar/IV Prêmio Nacional, 2001.

- PÊGAS, Paulo Henrique. **Manual de Contabilidade Tributária: teoria e prática.** 2 ed. Rio de Janeiro: Freitas Bastos, 2004.

- PINDYCK, Robert S. e RUBINFELD, Daniel. **Econometria – Modelos e Previsões.** 4 ed. Rio de Janeiro: Campus, 2005.

- ROSSETI, José Paschoal – **Introdução à Economia.** 17 ed. São Paulo: Atlas, 1997.

- SANTOS, Alan Vasconcelos. **Análise de Modelos de Séries Temporais para a Previsão Mensal do Imposto e Renda.** Universidade Federal do Ceará, Dissertação de Mestrado submetida ao Programa de Pós-graduação em Economia, 2003.

- SCHWERT, G. William. **Tests For Units Roots: A Monte Carlo Investigation.** Journal of Business & Economic Statistics, Abril 1989, vol. 7, nº 2.

- SILVER, Mick. **Estatística para Administração.** Tradução Sônia Vieira e José Eduardo Corrente. São Paulo; Atlas, 2000.

- SMAILES, Joanne, Mcgrane, Ângela. **Estatística Aplicada à Administração com Excel.** Tradução Christiane Brito. – São Paulo: Atlas, 2002.

- SOARES, Ilton G.Soaes e Ivan Castelar – **Econometria aplicada com o uso do Eviews.** Fortaleza: UFC/CAEN, 2003.

- TOLOI, Célia M.C., BRUSCATO, Adriana e ARTES, Rinaldo. **Aplicação de Modelos de Função de Transferência e Equações de Estimação para Previsão do Número de Passageiros em Ponte Aérea.**R.Bras.Estatística. Rio de janeiro, v. 64, n. 221, p.7-24, jan/jun. 2003.

- WOODRIDGE, Jeffrey. **Introdução à Econometria: uma abordagem moderna**; tradução Rogério César de Sousa, José Antônio Pereira; revisão técnica Nelson Carneiro. São Paulo, Pioneira Thomson Learning, 2006.

**ANEXOS**

**Tabela - 7 - Comportamento das FAC e FACP de um processo ARIMA( $p,d,q$ )**

<b>Ordem</b>	<b>(1, d, 0)</b>	<b>(0, d, 1)</b>
comportamento de $\rho_k$  comportamento de $\phi_{kr}$	decai exponencialmente somente para $\phi_{kk} \neq 0$ ou $\phi_{kk} = 0$ para $k > 1$	somente $\rho_1 \neq 0$ ou $\rho_1 = 0$ para $k > 1$ .  decaimento exponencial dominante
<b>Ordem</b>	<b>(2, d, 0)</b>	<b>(0, d, 2)</b>
comportamento de $\rho_k$  comportamento de $\phi_{kr}$	mistura de exponenciais ou ondas senóides amortecidas  somente para $\phi_{11} \neq 0$ e $\phi_{22} \neq 0$ ou $\phi_{kk} = 0$ para $k > 2$	somente $\rho_1 \neq 0$ e $\rho_2 \neq 0$ ou $\rho_1 = 0$ para $k > 2$  dominada por mistura de exponenciais ou senóides amortecidas.
<b>Ordem</b>	<b>(1, d, 1)</b>	
comportamento de $\rho_k$  comportamento de $\phi_{kr}$	decai exponencialmente após o lag 1  dominada por decaimento exponencial após o lag 1.	

Fonte: tabela elaborada pelo autor

**Tabela - 8 – Teste ADF da Série ICMSR: Período de Jan/96 a Dez/06**

Null Hypothesis: ICMSR has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.264386	0.0000
Test critical values: 1% level	-4.029595	
5% level	-3.444487	
10% level	-3.147063	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(ICMSR)

Method: Least Squares

Date: 07/09/07 Time: 11:01

Sample(adjusted): 1996:02 2006:12

Included observations: 131 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ICMSR(-1)	-0.464182	0.074099	-6.264386	0.0000
C	24793093	4238988.	5.848824	0.0000
@TREND(1996:01)	88455.41	20143.59	4.391244	0.0000
R-squared	0.237197	Mean dependent var		151025.7
Adjusted R-squared	0.225278	S.D. dependent var		7879424.
S.E. of regression	6935332.	Akaike info criterion		34.36479
Sum squared resid	6.16E+15	Schwarz criterion		34.43063
Log likelihood	-2247.894	F-statistic		19.90111
Durbin-Watson stat	2.157203	Prob(F-statistic)		0.000000

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 9 – Teste ADF da Série FPER: Período de Jan/96 a Dez/06**

Null Hypothesis: FPER has a unit root  
 Exogenous: Constant, Linear Trend  
 Lag Length: 0 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.294692	0.0000
Test critical values: 1% level	-4.029595	
5% level	-3.444487	
10% level	-3.147063	

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

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(FPER)  
 Method: Least Squares  
 Date: 07/09/07 Time: 11:11  
 Sample(adjusted): 1996:02 2006:12  
 Included observations: 131 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FPER(-1)	-0.605852	0.083054	-7.294692	0.0000
C	46120312	6767957.	6.814510	0.0000
@TREND(1996:01)	75214.68	30510.61	2.465197	0.0150
R-squared	0.294328	Mean dependent var		304326.4
Adjusted R-squared	0.283302	S.D. dependent var		14961088
S.E. of regression	12665763	Akaike info criterion		35.56934
Sum squared resid	2.05E+16	Schwarz criterion		35.63518
Log likelihood	-2326.792	F-statistic		26.69367
Durbin-Watson stat	1.916999	Prob(F-statistic)		0.000000

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 10 – Teste ADF da Série CONCIM: Período de Jan/96 a Dez/06**

Null Hypothesis: CONCIM has a unit root  
 Exogenous: Constant  
 Lag Length: 0 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.544454	0.0083
Test critical values: 1% level	-3.480818	
5% level	-2.883579	
10% level	-2.578601	

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

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(CONCIM)  
 Method: Least Squares  
 Date: 07/09/07 Time: 11:24  
 Sample(adjusted): 1996:02 2006:12  
 Included observations: 131 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CONCIM(-1)	-0.185362	0.052296	-3.544454	0.0005
C	4545.055	1280.573	3.549235	0.0005
R-squared	0.088746	Mean dependent var		127.3588
Adjusted R-squared	0.081682	S.D. dependent var		3511.387
S.E. of regression	3364.924	Akaike info criterion		19.09535
Sum squared resid	1.46E+09	Schwarz criterion		19.13924
Log likelihood	-1248.745	F-statistic		12.56316
Durbin-Watson stat	2.269783	Prob(F-statistic)		0.000549

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 11 – Teste ADF da Série CONENEG: Período de Jan/96 a Dez/06**

Null Hypothesis: CONENEG has a unit root  
 Exogenous: Constant, Linear Trend  
 Lag Length: 0 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.341188	0.0001
Test critical values: 1% level	-4.029595	
5% level	-3.444487	
10% level	-3.147063	

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

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(CONENEG)  
 Method: Least Squares  
 Date: 07/09/07 Time: 11:26  
 Sample(adjusted): 1996:02 2006:12  
 Included observations: 131 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CONENEG(-1)	-0.452418	0.084704	-5.341188	0.0000
C	2531860.	519799.6	4.870838	0.0000
@TREND(1996:01)	42940.56	8021.675	5.353066	0.0000
R-squared	0.186831	Mean dependent var		133382.7
Adjusted R-squared	0.174125	S.D. dependent var		1254892.
S.E. of regression	1140417.	Akaike info criterion		30.75432
Sum squared resid	1.66E+14	Schwarz criterion		30.82016
Log likelihood	-2011.408	F-statistic		14.70444
Durbin-Watson stat	1.952279	Prob(F-statistic)		0.000002

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 12 – Teste ADF da Série CREFFISCR: Período de Jan/96 a Dez/06**

Null Hypothesis: CREFFISR has a unit root

Exogenous: Constant

Lag Length: 1 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.685156	0.0000
Test critical values: 1% level	-3.481217	
5% level	-2.883753	
10% level	-2.578694	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(CREFFISR)

Method: Least Squares

Date: 07/09/07 Time: 11:29

Sample(adjusted): 1996:03 2006:12

Included observations: 130 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CREFFISR(-1)	-0.797317	0.103748	-7.685156	0.0000
D(CREFFISR(-1))	-0.086921	0.073190	-1.187611	0.2372
C	4937723.	954741.7	5.171789	0.0000
R-squared	0.442853	Mean dependent var	-83781.09	
Adjusted R-squared	0.434079	S.D. dependent var	10214668	
S.E. of regression	7684261.	Akaike info criterion	34.57005	
Sum squared resid	7.50E+15	Schwarz criterion	34.63623	
Log likelihood	-2244.053	F-statistic	50.47354	
Durbin-Watson stat	1.971622	Prob(F-statistic)	0.000000	

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 13 – Teste ADF da Série NUNFIS em nível: Período de Jan/96 a Dez/06**

Null Hypothesis: NUMFIS has a unit root

Exogenous: Constant

Lag Length: 2 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.730067	0.4138
Test critical values: 1% level	-3.481623	
5% level	-2.883930	
10% level	-2.578788	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(NUMFIS)

Method: Least Squares

Date: 07/09/07 Time: 11:36

Sample(adjusted): 1996:04 2006:12

Included observations: 129 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
NUMFIS(-1)	-0.085230	0.049264	-1.730067	0.0861
D(NUMFIS(-1))	-0.406796	0.087170	-4.666699	0.0000
D(NUMFIS(-2))	-0.331503	0.083633	-3.963800	0.0001
C	11.85550	8.283064	1.431295	0.1548
R-squared	0.250735	Mean dependent var	-0.271318	
Adjusted R-squared	0.232752	S.D. dependent var	60.30518	
S.E. of regression	52.82292	Akaike info criterion	10.80228	
Sum squared resid	348782.7	Schwarz criterion	10.89096	
Log likelihood	-692.7473	F-statistic	13.94336	
Durbin-Watson stat	2.130744	Prob(F-statistic)	0.000000	

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 14 - Critérios de Schwarz para ARMA(  $p$  e  $q$  ) – Máximo e Mínimo**

<b>Modelo ARMA(<math>p,q</math>)</b>	<b>SIC</b>
(5,5)	34.59280
(4,4)	34.54523
(3,3)	34.50590
(2,2)	34.45200
(1,1)	34.40961
(1,0)	34.38455
(2,0)	34.44086
(3,0)	34.46043
(4,0)	34.50102
(4,1)	34.50849
(4,2)	34.51028
(4,3)	34.54388
(3,0)	34.46043
(3,1)	34.44471
(3,2)	34.46915
(3,4)	34.49225
(3,5)	34.53608
(2,1)	34.40212
(2,3)	34.45767
(2,4)	34.50806
(2,5)	34.54148
(1,5)	34.50663
(1,4)	34.48646
(1,3)	34.43640
(1,2)	34.39833
(4,5)	34.52032

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 15 – Estimação do Modelo ARMA (1,0)**

Dependent Variable: ICMSR  
 Method: Least Squares  
 Date: 07/09/07 Time: 12:56  
 Sample(adjusted): 1996:02 2006:06  
 Included observations: 125 after adjusting endpoints  
 Convergence achieved after 10 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	54886204	2246047.	24.43680	0.0000
TEMPO	151188.4	30326.24	4.985399	0.0000
AR(1)	0.443277	0.081291	5.452945	0.0000
R-squared	0.450703	Mean dependent var	64572372	
Adjusted R-squared	0.441698	S.D. dependent var	9056283.	
S.E. of regression	6766819.	Akaike info criterion	34.31667	
Sum squared resid	5.59E+15	Schwarz criterion	34.38455	
Log likelihood	-2141.792	F-statistic	50.05101	
Durbin-Watson stat	2.040731	Prob(F-statistic)	0.000000	
Inverted AR Roots	.44			

Fonte: aplicativo Eviews

**Tabela - 16 – Correlograma dos Resíduos da Estimação do Modelo ARMA**  
**- Período: Jan/96 a Jun/06**

Date: 07/13/07 Time: 18:00

Sample: 1996:03 2006:06

Included observations: 124

Q-statistic  
probabilities  
adjusted for 1  
ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. .	. .	1 -0.007	-0.007	0.0068	
. .	. .	2 0.026	0.026	0.0914	0.762
. *	. *	3 0.069	0.069	0.6994	0.705
. .	. .	4 -0.051	-0.051	1.0396	0.792
. .	. .	5 -0.034	-0.038	1.1889	0.880
. .	. .	6 0.007	0.004	1.1950	0.945
* .	. .	7 -0.059	-0.051	1.6636	0.948
* .	* .	8 -0.064	-0.064	2.2207	0.947
. .	. .	9 -0.002	-0.005	2.2214	0.973
. .	. .	10 -0.034	-0.024	2.3784	0.984
. .	. .	11 -0.023	-0.021	2.4533	0.992
. .	. .	12 0.012	0.003	2.4726	0.996
. .	. .	13 0.019	0.020	2.5226	0.998
. .	. .	14 -0.007	-0.010	2.5291	0.999
. **	. **	15 0.272	0.264	13.165	0.514
. *	. *	16 0.134	0.145	15.777	0.397
. .	. .	17 -0.023	-0.032	15.854	0.463
. .	. .	18 0.028	-0.022	15.967	0.526
. .	. .	19 -0.031	-0.026	16.111	0.585
. .	. .	20 0.023	0.060	16.192	0.644
. .	. .	21 -0.033	-0.030	16.355	0.694
. .	. .	22 0.001	0.022	16.355	0.749
. .	. .	23 -0.016	0.024	16.393	0.796
. .	. .	24 0.016	0.039	16.436	0.836
. .	. .	25 -0.002	0.012	16.436	0.872
. .	. .	26 0.008	0.019	16.446	0.901
. .	. .	27 -0.017	-0.017	16.491	0.924
. .	. .	28 -0.026	-0.038	16.603	0.940
. .	. .	29 -0.037	-0.045	16.823	0.952
. .	* .	30 -0.021	-0.097	16.897	0.964
. .	* .	31 -0.014	-0.100	16.932	0.973
. .	. .	32 -0.028	-0.036	17.065	0.980
. .	. .	33 -0.040	-0.035	17.338	0.984
. .	. .	34 -0.005	0.008	17.343	0.989
. *	. *	35 0.091	0.084	18.793	0.984
. .	. .	36 -0.004	0.008	18.795	0.989

Fonte: aplicativo Eviews

**Tabela - 17 - Critérios de Schwarz para Função de Transferência**  
**- Defasagens de 1 a 5 –**

<b>Modelo FT</b>	<b>SIC</b>
lcms(-1)fper concim	34.39857
lcms(-1) fper(-1)concim	34.43268
lcms(-1) fper(-1) concim(-1)	34.45865
lcms(-2) fper(-2) concim(-2)	34.54557
fper(-1) concim (-1)	34.61615
fper(-2) concim (-2)	34.69564
lcms(-3) fper concim	34.47134
lcms(-4) fper concim	34.51892
lcms(-2) fper(-1) concim	34.46520

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 18 – Estimação do Modelo Função de Transferência**

Dependent Variable: ICMSR

Method: Least Squares

Date: 07/09/07 Time: 13:32

Sample(adjusted): 1996:02 2006:06

Included observations: 125 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	19532380	6101412.	3.201289	0.0018
TEMPO	78042.02	19388.45	4.025181	0.0001
ICMSR(-1)	0.403357	0.083055	4.856500	0.0000
FPER	0.098917	0.046644	2.120679	0.0360
CONCIM	246.1496	110.6228	2.225125	0.0279
R-squared	0.484358	Mean dependent var	64572372	
Adjusted R-squared	0.467170	S.D. dependent var	9056283.	
S.E. of regression	6610654.	Akaike info criterion	34.28544	
Sum squared resid	5.24E+15	Schwarz criterion	34.39857	
Log likelihood	-2137.840	F-statistic	28.17989	
Durbin-Watson stat	2.016188	Prob(F-statistic)	0.000000	

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 19 – Correlograma dos Resíduos da Estimação da Função de Transferência- Período: Jan/96 a Jun/06**

Date: 07/13/07 Time: 18:01

Sample: 1996:03 2006:06

Included observations: 124

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. .	. .	1 -0.053	-0.053	0.3548	0.551
. .	. .	2 -0.013	-0.016	0.3767	0.828
. .	. .	3 0.002	0.001	0.3774	0.945
. .	. .	4 -0.049	-0.049	0.6936	0.952
. .	. .	5 -0.035	-0.041	0.8552	0.973
. .	. .	6 0.039	0.034	1.0562	0.983
. .	. .	7 -0.046	-0.044	1.3396	0.987
* .	* .	8 -0.060	-0.067	1.8322	0.986
. .	. .	9 0.036	0.025	2.0087	0.991
. .	. .	10 -0.043	-0.041	2.2675	0.994
. .	. .	11 -0.015	-0.021	2.2980	0.997
. .	. .	12 -0.010	-0.025	2.3133	0.999
. .	. .	13 0.000	-0.002	2.3133	0.999
. .	. .	14 -0.004	-0.005	2.3153	1.000
. **	. **	15 0.262	0.253	12.146	0.668
. *	. *	16 0.125	0.164	14.419	0.568
. .	. .	17 -0.040	-0.013	14.652	0.621
. .	. .	18 0.009	0.005	14.663	0.685
. .	. .	19 -0.027	-0.001	14.772	0.737
. .	. .	20 0.017	0.047	14.814	0.787
. .	. .	21 -0.035	-0.044	14.994	0.823
. .	. .	22 0.006	0.011	15.001	0.862
. .	. .	23 -0.019	0.025	15.057	0.893
. .	. .	24 0.010	0.013	15.072	0.919
. .	. .	25 -0.001	0.011	15.073	0.940
. .	. .	26 0.015	0.034	15.109	0.955
. .	. .	27 -0.013	0.004	15.135	0.967
. .	. .	28 -0.020	-0.019	15.198	0.976
. .	. .	29 -0.040	-0.057	15.457	0.981
. .	* .	30 -0.028	-0.111	15.584	0.986
. .	* .	31 0.022	-0.079	15.661	0.990
. .	* .	32 -0.038	-0.062	15.900	0.992
. .	. .	33 -0.023	-0.038	15.990	0.994
. .	. .	34 0.012	0.003	16.015	0.996
. .	. .	35 0.045	0.034	16.369	0.997
. .	. .	36 -0.024	-0.007	16.468	0.998

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 22 – Critérios de Schwarz para ARMA (  $p$  e  $q$  ) Reestimados –  
Máximo e Mínimo**

<b>Modelo ARMA</b>	<b>SIC</b>
(5,5)	34.40827
(4,4)	34.40782
(3,3)	34.39756
(2,2)	34.33323
(1,1)	34.30919
(1,0)	34.27455
(2,0)	34.31616
(3,0)	34.35953
(4,0)	34.39894
(4,1)	34.40992
(4,2)	34.38730
(4,3)	34.37927
(3,0)	34.35953
(3,1)	34.37133
(3,2)	34.38658
(3,4)	34.34391
(3,5)	34.46215
(2,1)	34.29550
(2,3)	34.25485
(2,4)	34.40649
(2,5)	34.44344
(1,5)	34.40389
(1,4)	34.41532
(1,3)	34.38464
(1,2)	34.34768
(4,5)	34.36427
(5,4)	34.25489
(5,3)	34.38021
(5,2)	34.46808
(5,1)	34.44838
(5,0)	34.42816

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 23 – Reestimação do Modelo ARMA (2,3)**

Dependent Variable: ICMSR  
 Method: Least Squares  
 Date: 07/17/07 Time: 16:43  
 Sample(adjusted): 1996:03 2006:06  
 Included observations: 124 after adjusting endpoints  
 Convergence achieved after 51 iterations  
 Backcast: OFF (Roots of MA process too large)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	58004412	1329473.	43.62964	0.0000
DJAN85	-63145898	8017616.	-7.875894	0.0000
TEMPO	88712.18	26638.05	3.330280	0.0012
TEMPO*DJAN03	623693.4	74878.88	8.329363	0.0000
AR(1)	0.873781	0.213088	4.100561	0.0001
AR(2)	-0.072045	0.161237	-0.446825	0.6558
MA(1)	-0.761887	0.252713	-3.014826	0.0032
MA(2)	-0.248582	0.174685	-1.423030	0.1574
MA(3)	-0.108111	0.138362	-0.781366	0.4362
R-squared	0.619723	Mean dependent var	64623377	
Adjusted R-squared	0.593269	S.D. dependent var	9074978.	
S.E. of regression	5787609.	Akaike info criterion	34.05015	
Sum squared resid	3.85E+15	Schwarz criterion	34.25485	
Log likelihood	-2102.109	F-statistic	23.42640	
Durbin-Watson stat	2.199287	Prob(F-statistic)	0.000000	
Inverted AR Roots	.78	.09		
Inverted MA Roots	1.08	-.16+.27i	-.16 -.27i	
Estimated MA process is noninvertible				

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 24 - Critérios de Schwarz para Função de Transferência**  
**- Defasagens de 1 a 5 –**

<b>Modelo FT</b>	<b>SIC</b>
lcms(-1)fper concim	34.31378
lcms(-1) fper(-1)concim	34.32749
lcms(-1) fper(-1) concim(-1)	34.33461
lcms(-2) fper(-2) concim(-2)	34.35970
fper(-1) concim (-1)	34.34054
fper(-2) concim (-2)	34.32119
lcms(-3) fper concim	34.37395
lcms(-4) fper concim	34.35935
lcms(-2) fper(-1) concim	34.38858

Fonte: elaborada pelo autor através do aplicativo Eviews

**Tabela - 25 – Reestimação da Função de Transferência**  
**Período: Jan/96 a Jun/06**

Dependent Variable: ICMSR  
 Method: Least Squares  
 Date: 07/17/07 Time: 17:12  
 Sample(adjusted): 1996:02 2006:06  
 Included observations: 125 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	37263411	7152830.	5.209604	0.0000
DJAN85	-44383080	10556113	-4.204491	0.0001
TEMPO	50613.91	31468.14	1.608417	0.1104
TEMPO*DJAN03	455459.4	101622.2	4.481888	0.0000
ICMSR(-1)	0.207075	0.089272	2.319589	0.0221
FPER	0.061154	0.045336	1.348886	0.1800
CONCIM	186.3369	115.5736	1.612279	0.1096
R-squared	0.561497	Mean dependent var	64572372	
Adjusted R-squared	0.539200	S.D. dependent var	9056283.	
S.E. of regression	6147607.	Akaike info criterion	34.15539	
Sum squared resid	4.46E+15	Schwarz criterion	34.31378	
Log likelihood	-2127.712	F-statistic	25.18289	
Durbin-Watson stat	1.961102	Prob(F-statistic)	0.000000	

Fonte: elaborada pelo autor através do aplicativo Eviews