

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS JURÍDICAS E ECONÔMICAS
MESTRADO EM ECONOMIA**

BERNARDINO JOSAFAT DA SILVA CASTANHO

**MODELOS PARA PREVISÃO DE RECEITAS
TRIBUTÁRIAS: O ICMS DO ESTADO DO ESPÍRITO
SANTO**

**VITÓRIA
2011**

BERNARDINO JOSAFAT DA SILVA CASTANHO

**MODELOS PARA PREVISÃO DE RECEITAS
TRIBUTÁRIAS: O ICMS DO ESTADO DO ESPÍRITO
SANTO**

Dissertação apresentada no Programa de Mestrado em Economia da Universidade Federal do Espírito Santo, como requisito para a obtenção do título de Mestre em Economia.

Orientador: Profº Dr. Gutemberg Hespanha Brasil.

VITÓRIA
2011

BERNARDINO JOSAFAT DA SILVA CASTANHO

**MODELOS PARA PREVISÃO DE RECEITAS
TRIBUTÁRIAS: O ICMS DO ESTADO DO ESPÍRITO
SANTO**

Dissertação apresentada no Programa de Mestrado em Economia da Universidade Federal do Espírito Santo, como requisito para a obtenção do título de Mestre em Economia.

Orientador: Profº Dr. Gutemberg Hespanha Brasil.

Aprovada em 01 de abril de 2011.

BANCA EXAMINADORA

Profº Dr. Gutemberg Hespanha Brasil.
Universidade Federal do Espírito Santo
Orientador

Profº Dr. Rogério Arthmar.
Universidade Federal do Espírito Santo

Profº Dr. Robert Wayne Samohyl.
Universidade Federal de Santa Catarina

A Rosemeire, Aline e Matheus, razões da minha existência.

A Oneide e Arcelino, usados por Deus para me darem a vida.

“Não que, por nós mesmos, sejamos capazes de pensar alguma coisa, como se partisse de nós; mas a nossa capacidade vem de Deus”

II Coríntios 3:5

“An economist is an expert who will know tomorrow why the things he predicted yesterday didn't happen today.”

Evan Esar

RESUMO

Esta dissertação tem como principal objetivo a pesquisa de um modelo formal para a previsão de receitas tributárias estaduais do ICMS do Estado do Espírito Santo a partir da análise dos dados da série temporal da arrecadação no período de janeiro de 2000 a dezembro de 2009 e da composição da base de incidência tributária do imposto.

Foram identificadas as características estatísticas da série do ICMS e elaboradas previsões com utilização dos modelos de alisamento exponencial de Holt-Winters, da metodologia de Box-Jenkins, com análise de intervenção para detecção de mudança estrutural, e de um modelo econométrico causal com estrutura dinâmica.

Para a especificação do modelo econométrico foram identificados os setores mais relevantes da economia que compõem a base tributária do ICMS e influenciam diretamente a arrecadação. Foi escolhida a modelagem econométrica mista com regressão múltipla e uma só equação comportamental.

O desempenho preditivo dos modelos foi comparado através do erro percentual absoluto médio, para a escolha daquele que apresentar a melhor estimativa para o ano de 2010, utilizado como base de avaliação da eficiência da previsão *ex-post* gerada.

Palavras Chave: ICMS. Previsão. Arrecadação de Impostos. Modelo Econométrico.

ABSTRACT

The main objective of this dissertation is the research of a formal model for the monthly forecast of the Value Added Taxes on sales and services (ICMS) collected by the State of Espírito Santo, derived from the term series data analysis of the tax revenue from January 2000 to December 2009 and from the composition basis of the taxation incidence of the tax.

The statistical characteristics of the ICMS series were identified and forecasts were drawn up with the use of Holt-Winters exponential smoothing models, of Box-Jenkins methodology, with intervention analysis for structural change detection and of a causal econometric model with dynamic structure.

For the specification of the econometric model, the most relevant sectors of the economy that compose the ICMS tax basis and directly influence the tax revenue have been identified. It was chosen the mixed econometric model with multiple regression and only one behavioral equation.

The predictive performance of the models was compared through the mean absolute percentage error (MAPE), in order to choose the one that shows the best estimate for the year 2010, used as basis of efficiency evaluation of the generated *ex-post* forecast.

Keywords: ICMS. Forecast. Tax Revenue. Econometric Model.

LISTA DE GRÁFICOS

Gráfico 1: Composição aproximada da base tributária do ICMS-ES	17
Gráfico 2: Evolução do PIB-ES de 1995 a 2007.....	19
Gráfico 3: Arrecadação do ICMS de Jan/2000 a Ago/2010.....	26
Gráfico 4: Filtro de Hodrick-Prescott ($\lambda = 14400$)	27
Gráfico 5: Primeira diferença da série do ICMS	29
Gráfico 6: Composição do ICMS-ES, Jan a Ago 2007	32
Gráfico 7: Previsão do ICMS com modelo exponencial logarítmico.	36
Gráfico 8: Gráficos das séries variáveis descritas	45
Gráfico 9: Intervenção impulso 1.....	58
Gráfico 10: Intervenção impulso 2	58
Gráfico 11: Intervenção impulso 3	58
Gráfico 12: Intervenção degrau1.....	59
Gráfico 13: Intervenção degrau 2.....	59
Gráfico 14: Intervenção degrau 3.....	59
Gráfico 15: Modelo de Holt não sazonal.....	66
Gráfico 16: Modelo de Holt-Winters aditivo	68
Gráfico 17: Modelo de Holt-Winters multiplicativo.....	69
Gráfico 18: FAC e FACP das séries $\log(\text{ICMS})$ e $d\log(\text{ICMS})$	72
Gráfico 19: Diagrama dos resíduos ARIMA	76
Gráfico 20: Previsões do modelo ARIMA	76
Gráfico 21: FAC e FACP para N_t e dN_t	79
Gráfico 22: Arrecadação ICMS Jul/2007 a Dez/2008 e função intervenção.....	80
Gráfico 23: Previsões do modelo ARIMA com intervenção.....	82
Gráfico 24: Séries transformadas por logaritmo natural.....	87
Gráfico 25: Séries explicativas em primeiras diferenças.....	89
Gráfico 26: Previsões e avaliação do modelo econométrico.....	99
Gráfico 27: Arrecadação do ICMS no ano de 2010	106

LISTA DE TABELAS

Tabela 1: Evolução da Receita Tributária Estadual	18
Tabela 2: Teste de Raiz Unitária para ICMS.....	28
Tabela 3: Sazonalidade com Variáveis Dummies	30
Tabela 4: Modelo GARCH (1,1) para a Série DICMS	31
Tabela 5: Previsão do ICMS pelo Modelo de Holt	67
Tabela 6: Previsão do Modelo Holt-Winters Aditivo.....	68
Tabela 7: Previsão do Modelo Holt-Winters Multiplicativo	70
Tabela 8: Parâmetros para os Modelos de Holt-Winters da Série do ICMS.....	70
Tabela 9: Características Teóricas das ACF e PACF	71
Tabela 10: Avaliação dos Modelos ARIMA para dlog(ICMS)	74
Tabela 11: Parâmetros e Correlograma dos Resíduos do Modelo (2)	75
Tabela 12: Valores das previsões do modelo ARIMA c ar(1) ar(2)	77
Tabela 13: Teste de Chow para o Modelo Box-Jenkins.....	78
Tabela 14: Parâmetros do Modelo Residual.....	79
Tabela 15: Parâmetros e Correlograma dos Resíduos para o Modelo com Intervenção.....	81
Tabela 16: Previsão com intervenção tipo degrau em dez/2008.....	82
Tabela 17: Teste ADF da Raiz Unitária para Todas as Séries	88
Tabela 18: Estimação Inicial da Equação de Longo Prazo	90
Tabela 19: Teste de Causalidade de Granger.....	91
Tabela 20: Teste de Cointegração de Engle-Granger.....	92
Tabela 21: Parâmetros da Eq. de Longo Prazo e teste ADF para os Resíduos.....	92
Tabela 22: Parâmetros da Eq. de Curto Prazo e teste ADF para os Resíduos.....	94
Tabela 23: Valores da Previsão Dinâmica do Modelo de Curto Prazo.....	99
Tabela 24: Características dos Métodos Utilizados	102
Tabela 25: Erros de Previsão para Período sem Intervenção	103
Tabela 26: EPAM Acumulados para os Modelos Calculados.....	104

LISTA DE SIGLAS

ANP – Agência Nacional do Petróleo
ARIMA – Autoregressive Integrated Moving Average
BCB – Banco Central do Brasil
CONFAZ – Conselho Nacional de Política Fazendária
COTEPE – Comissão Técnica Permanente do ICMS.
DOLS – Dynamic Ordinary Least Squares
EPAM – Erro Percentual Absoluto Médio
FAC – Função de Autocorrelação
FACP – Função de Autocorrelação Parcial
FUNDAP – Fundo para o Desenvolvimento da Atividade Portuária
IBGE – Instituto Brasileiro de Geografia e Estatística
ICM – Imposto sobre Circulação de Mercadorias (extinto)
ICMS – Imposto sobre Circulação de Mercadorias e Serviços
ICMSH – Previsão do ICMS pelo modelo de Holt
ICMSHWA – Previsão do ICMS pelo modelo Holt-Winters aditivo
ICMSHWM – Previsão do ICMS pelo modelo Holt-Winters multiplicativo
II – Imposto de Importação
IJSN – Instituto Jones dos Santos Neves
IPEA – Instituto de Planejamento e Economia Aplicada
IPEADATA – Banco de Dados do IPEA
IRPJ – Imposto de Renda Pessoal Jurídica
IVA – Imposto sobre o Valor Agregado
IVC – Imposto sobre Vendas e Consignações
LRF – Lei de Responsabilidade Fiscal
MAPE – Mean Absolute Percentual Error
MCE – Mecanismo de correção de erros
MDIC – Ministério do Desenvolvimento Indústria e Comércio
MTE – Ministério do Trabalho e Emprego
MQO – Método dos Mínimos Quadrados Ordinários
PIB – Produto Interno Bruto
RICMS/ES – Regulamento do ICMS do estado do Espírito Santo
RMSE – Root Mean Square Error
SARIMA – Seasonal Autoregressive Integrated Moving Average
SECEX – Secretaria de Comércio Exterior
SEFAZ – Secretaria Estadual de Fazenda
SINIEF – Sistema Nacional de Informações Econômico-Fiscais

SUMÁRIO

RESUMO.....	6
ABSTRACT	7
LISTA DE GRÁFICOS.....	8
LISTA DE TABELAS	9
LISTA DE SIGLAS	10
SUMÁRIO.....	11
1. INTRODUÇÃO	13
1.1 Considerações Gerais	13
1.2 Questão a Investigar.....	15
1.3 Objetivos.....	16
1.4 Justificativa e Importância do Estudo.....	18
1.5 Estrutura do Trabalho	19
1.6 Limitações do projeto.....	20
2. O ICMS E A PREVISÃO DE RECEITAS.....	21
2.1 Histórico do ICMS	21
2.2 O ICMS no Estado do ES	24
2.2.1 O Sistema Fundap	25
2.3 Características Estatísticas da Série do ICMS ES.....	26
2.3.1 O Gráfico	26
2.3.2 Tendência e Estacionariedade	27
2.3.3 Ciclos e Sazonalidade.....	29
2.3.4 Volatilidade.....	31
2.4 A composição da Base Tributária do ICMS	32
2.5 A Previsão de Receitas no ES.....	33
2.6 Trabalhos no Brasil	36
2.7 Metodologia	40
2.7.1 A Base de Dados	40
2.7.2 Descrição das Variáveis.....	42
2.7.3 Modelos Propostos.....	45
2.7.4 Tratamento dos Dados.....	47
3. REFERENCIAL TEÓRICO.....	49
3.1 Métodos Quantitativos de Previsão	49
3.1.1 Modelo de Alisamento Exponencial de Holt.....	49

3.1.2	Modelo de Alisamento Exponencial Sazonal de Holt-Winters.....	51
3.1.3	Modelos ARIMA de Box-Jenkins.....	53
3.1.4	Análise de Intervenção.....	56
3.1.5	Modelos Causais ou Econométricos Dinâmicos	60
3.2	Teste ADF para Raízes Unitárias	61
3.3	Teste de Cointegração.....	62
3.4	Mecanismo de Correção de Erros	63
3.5	A Crise Financeira Internacional.....	65
4.	MODELOS DE SÉRIES TEMPORAIS E PREVISÕES	66
4.1	Alisamento Exponencial de Holt	66
4.2	Alisamento Exponencial de Holt-Winters Aditivo	67
4.3	Alisamento Exponencial de Holt-Winters Multiplicativo.....	69
4.4	Modelo de Box-Jenkins.....	71
4.5	Modelo ARIMA com Análise de Intervenção.....	78
5.	MODELO ECONOMETRICO DINÂMICO	83
5.1	Abordagem do Modelo Geral para o Específico	85
5.2	Seleção das Variáveis	86
5.3	Análise da Estacionariedade e da Ordem de Integração.....	87
5.3.1	Aplicação do Teste das Raízes Unitárias.....	88
5.4	Marginalização e Condicionamento	89
5.4.1	Teste de Causalidade de Granger	90
5.4.2	Teste de Cointegração	92
5.5	Reparametrização e Redução	93
5.6	Testes de Especificação e Previsões	95
5.6.1	Previsões	96
6.	CONCLUSÃO	101
6.1	Considerações Gerais	101
6.2	Avaliação dos modelos	102
6.3	Recomendações	107
7.	REFERÊNCIAS.....	110
8.	APÊNDICE A	115

1. INTRODUÇÃO

1.1 Considerações Gerais

A prestação de contas por parte dos governantes é uma das conquistas da democracia que deve ser posta em prática na elaboração, execução e controle do orçamento público. Na história econômica do Brasil encontramos sucessivas referências a planos de desenvolvimento econômico e social nos quais a disponibilidade de recursos públicos oriundos da arrecadação de tributos desempenha importante papel na consecução dos objetivos propostos. O cumprimento das metas requer dos gestores não só uma perfeita avaliação do impacto macroeconômico de suas ações, mas também da disponibilidade de suas receitas presente e futuras. Em conseqüência, as tarefas de estimação, previsão e controle de receitas fiscais têm recebido crescente interesse acadêmico e especial atenção de políticos, autoridades monetárias, institutos de pesquisa e do público contribuinte.

Conforme análise de Armstrong (1988) em pesquisa realizada para o período de 1900 a 1986, o interesse acadêmico pelo assunto em questão é constatado pelo crescente número de publicações sobre *forecasting* nos Estados Unidos da América.

Estudo do Banco Central Europeu de 2007 (LEAL, 2007) destaca a necessidade de obtenção de técnicas de previsões econômicas e fiscais cada vez mais consistentes e acuradas para subsidiar as decisões dos governantes. E conclui afirmando que a previsão de receitas fiscais é mais do que uma ciência, é uma arte que deve ser aperfeiçoada com o uso de indicadores de eficiência e análises políticas.

O ICMS (Imposto sobre Circulação de Mercadorias e Serviços) é a principal fonte de receita dos estados brasileiros, correspondendo a mais de 50% do total da arrecadação tributária. A reforma tributária presente na Constituição Federal de 1988 ampliou o grau de autonomia dos estados atribuindo-lhes competência para fixar autonomamente as suas alíquotas do ICMS, ao mesmo tempo em que foram retiradas restrições ao emprego dos recursos assim obtidos, bem como limitações impostas ao poder de legislar dos estados a respeito da matéria.

Desde então, e notadamente após o advento da Lei de Responsabilidade Fiscal, de maio de 2000, que tornou essencial a estimação e a previsão das receitas públicas

para uma boa gestão fiscal, que essa matéria tem despertado o interesse de gestores públicos, economistas e estudiosos no Brasil.

Considerando a variedade de métodos disponíveis e o constante aperfeiçoamento das técnicas econométricas de previsão baseadas em séries temporais, vários trabalhos têm sido desenvolvidos no Brasil no âmbito federal e estadual para atender essa importante demanda.

No Brasil, conforme relata Corvalão (2002), somente a partir de 1994 encontram-se trabalhos econométricos relevantes sobre o assunto, aplicados à estimação e à previsão de receitas fiscais, com destaque para o ICMS. Outros trabalhos serão objeto de consideração no capítulo dois.

As mudanças na estrutura tributária do país introduzidas pela Constituição Federal de 1988 acentuaram e consolidaram uma situação de desequilíbrio do setor público já agravada pela escalada inflacionária crônica, com seu auge na década de 80, e pelos déficits fiscais oriundos, em parte, da impossibilidade de qualquer previsão orçamentária razoável, em vista da instável conjuntura econômica.

A partir de 1994, com o advento do Plano Real, a economia no Brasil experimentou relativa e continuada estabilidade, refletida principalmente no controle do índice de inflação em patamares razoáveis para uma economia em desenvolvimento. Essa estabilidade teve como efeito colateral imediato a exposição do grave desequilíbrio das contas públicas, assoberbadas com dívidas além da capacidade de pagamento da sua receita fiscal, tanto na esfera federal como, nas estaduais e municipais.

Para resolver esse desajuste orçamentário a partir do diagnóstico de suas causas, a Lei de Responsabilidade Fiscal – Lei Complementar nº 101, de 04/05/2000, teve como principal objetivo, de acordo com o *caput* de seu art. 1º, estabelecer “normas de finanças públicas voltadas para a responsabilidade na gestão fiscal.” O seu artigo 11 define os requisitos essenciais dessa responsabilidade:

Art. 11. 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.

Essa lei traz como inovação um novo conceito de equilíbrio para as contas públicas, representado pelo equilíbrio auto-sustentável das “contas primárias”, que não gera aumento da dívida pública. As estimativas de receita deverão ser acompanhadas de

demonstrativos de sua evolução nos três anos anteriores e nos três anos seguintes àqueles a que se referir.

O equilíbrio das contas públicas do Estado do Espírito Santo alcançado gradativamente a partir de 2003, mediante ações efetivas de controle de gestão, induziu um novo ciclo de desenvolvimento econômico no Estado, evidenciado pelo continuado aumento da arrecadação tributária e pelo incremento de novos investimentos produtivos, o que proporcionou taxas médias de crescimento acima da média nacional, conforme dados divulgados pelo IBGE. Para a manutenção desse equilíbrio e a aplicação planejada e eficiente dos recursos públicos arrecadados, a tarefa de estimação e previsão de receitas adquire real importância.

A atual metodologia de previsão de receitas utilizada pelo estado baseia-se em métodos preditivos utilizando a linha de tendência da arrecadação, associada a critérios qualitativos, que levam em conta a conjuntura econômica e fatores relevantes de política fiscal que possam produzir acréscimos ou decréscimos na receita esperada.

A elaboração de modelos econométricos de *forecasting* com base na teoria econômica e nas características da base tributária observada deverá proporcionar estimativas mais confiáveis e modelos mais ajustados à realidade do estado.

1.2 Questão a Investigar

Os órgãos governamentais administradores de tributos têm a necessidade de estimar a arrecadação fiscal anualmente ou em intervalos menores, para servir de subsídio para o planejamento orçamentário e alocação de recursos públicos para o desenvolvimento social e econômico. A peça fundamental do orçamento é o montante da receita total, da qual a receita tributária é a mais significativa. A estimação desses recursos poderá ser de natureza qualitativa e/ou quantitativa dependendo dos elementos da conjuntura econômica e dos dados históricos disponíveis.

As técnicas para estimação quantitativa baseiam-se no desenvolvimento de modelos econométricos causais elaborados com base na teoria econômica e na legislação tributária vigente, de onde são extraídas relações de causa e efeito entre variáveis explicativas relevantes e a arrecadação em estudo; e também na análise de séries

temporais que, segundo Makridakis *et al.* (1998), são seqüências ordenadas de valores de uma variável, observadas em intervalos de tempo igualmente espaçados. Essas seqüências podem ter natureza determinística ou aleatória e, portanto, podem ou não apresentar um padrão de evolução passível de serem modelados matematicamente para emprego em previsões.

O escopo desta dissertação é a economia do Estado do Espírito Santo, enfocando o total da arrecadação fiscal gerada pelo ICMS, administrado pela Secretaria Estadual de Fazenda (SEFAZ-ES). Visa a análise da estrutura formadora da arrecadação do ICMS com base em dados extraídos do perfil da economia atual, para a elaboração de um modelo econométrico causal e também a aplicação de técnicas de *forecasting* baseadas na série histórica do imposto para a escolha do modelo que melhor servirá para previsão da arrecadação.

1.3 Objetivos

Este trabalho tem como objetivos analisar a série temporal da arrecadação do ICMS do Estado do Espírito Santo, no período de 2000 a 2009 e elaborar previsões utilizando vários modelos econométricos e de séries temporais visando à escolha de um modelo de previsão que melhor se ajuste às características econômicas do ICMS no Estado. Para a composição do modelo econométrico serão identificados os setores mais relevantes da economia que, com base na teoria econômica, integram a base tributária do ICMS e influenciam diretamente a arrecadação. As eficiências dos modelos serão avaliadas pelo EPAM (Erro Percentual Absoluto Médio) para a escolha daquele que apresentar a melhor estimativa da previsão para o ano de 2010, ano que será utilizado como parâmetro de comparação.

Para atingir o objetivo principal podemos relacionar os seguintes objetivos secundários:

- Analisar as características estatísticas da série temporal do ICMS do ES;
- Aplicar modelos de séries temporais de Holt-Winters, Box-Jenkins e Box-Jenkins com intervenção para previsão da arrecadação do ICMS;
- Identificar os setores mais relevantes para a formação da receita tributária do ICMS-ES;

- Elaborar modelo econométrico causal dinâmico;
- Comparar e avaliar a eficiência preditiva dos modelos ajustados para o período de jan a ago de 2010.
- Propor previsões para a arrecadação do imposto.

A análise da economia do Estado permite a elaboração do seguinte gráfico 1 que, por hipótese e com base nos relatórios de arrecadação da SEFAZ-ES (SEFAZ-ES, 2007), explica aproximadamente o fluxo de receitas geradas pela arrecadação do ICMS:




Gráfico 1: Composição aproximada da base tributária do ICMS-ES

1.4 Justificativa e Importância do Estudo

A tarefa de estimação, previsão e controle de receitas fiscais têm recebido crescente interesse acadêmico e especial atenção de políticos, autoridades monetárias, institutos de pesquisa e do público contribuinte.

A importância estratégica que a previsão de receitas representa para os órgãos de governo tem motivado a elaboração de vários trabalhos acadêmicos para o estudo da previsão de receitas públicas nos níveis federal, estadual e municipal no Brasil.

A complexidade do Sistema Tributário Brasileiro, a natureza do tributo analisado e as características econômicas regionais e locais, exigem um estudo de caso para cada tipo de receita tributária, em particular a do ICMS, que possui legislação própria em cada Estado.

A Secretaria de Estado da Fazenda do Espírito Santo não dispõe de método econométrico estruturado para a realização de previsões no contexto das receitas tributárias. Estimativas são realizadas com base em análises qualitativas conjunturais e eventualmente utilizando projeções matemáticas elementares das diversas linhas de tendência no tempo, segundo o trabalho de Oliveira (2004).

As particularidades do ICMS-ES, especialmente sua expressiva participação na receita tributária e a relevante contribuição do setor de comércio exterior, reforçam a necessidade da existência de uma metodologia de previsão que utilize modelos adequados à realidade da economia local. Esse modelo poderá servir de base para novas pesquisas visando à melhoria da acurácia das estimações. A tabela 1 mostra que a participação do ICMS na arrecadação tributária estadual variou de 92,23% a 95,32% no período de 2000 a 2009.

Tabela 1: Evolução da Receita Tributária Estadual

TRIB	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009
ICMS	2004533	2490518	2364264	2895903	3670722	4540145	5028240	5878468	7001267	6670459
Taxas	54778	62247	88678	100859	123611	145896	165531	204705	240351	247628
IPVA	78065	56099	66228	77654	107485	132692	158156	207182	248209	294789
ITCD	3144	4007	5057	4663	5206	6130	10819	13996	16449	19055
Total	2140520	2612871	2524227	3079079	3907024	4824863	5362746	6304351	7506276	7231931
% ICMS	93,65%	95,32%	93,66%	94,05%	93,95%	94,10%	93,76%	93,24%	93,27%	92,23%

Fonte: CONFAZ/COTEPE - Comissão Técnica Permanente do ICMS. Valores em R\$ mil.

O crescimento econômico do Estado evidenciado pelo crescimento expressivo do seu produto interno bruto (PIB) a partir do ano de 2002, conforme mostra o gráfico 2, induziu o aumento da arrecadação tributária, que poderá ser empregada para impulsionar o desenvolvimento a partir de um planejamento orçamentário amparado em projeções de arrecadação baseadas em métodos preditivos econométricos confiáveis.




Gráfico 2: Evolução do PIB-ES de 1995 a 2007

Fonte: Instituto Jones dos Santos Neves – IJSN

http://www.ijsn.es.gov.br/attachments/310_Série_Retropolada_1995-2007_Ano%20Base%202002.xls

1.5 Estrutura do Trabalho

O trabalho está estruturado em seis capítulos conforme a descrição a seguir:

No Capítulo I é apresentada a importância e justificativa do estudo, os objetivos a serem alcançados, a metodologia e as limitações identificadas no trabalho.

O Capítulo II traz um histórico do ICMS e a caracterização do imposto no estado do Espírito Santo, com destaque para a composição da base tributária do imposto, a previsão de receitas e os trabalhos realizados no Brasil.

O Capítulo III apresenta o referencial teórico e as metodologias utilizadas para a construção dos modelos.

A análise empírica e as previsões para a arrecadação do ICMS são desenvolvidas no Capítulo IV e o Capítulo V contém o desenvolvimento do modelo econométrico e as respectivas previsões.

O Capítulo VI é destinado a conclusão e sugestões para trabalhos futuros.

1.6 Limitações do projeto

A incerteza inerente ao ambiente econômico, aliada à forte influência que as expectativas dos agentes desempenham sobre o comportamento das variáveis tornam a tarefa de estimar o comportamento destas, um grande desafio; e para muitos, uma arte.

A definição do modelo de uma regressão requer a escolha das variáveis adequadas e um amplo conhecimento das relações entre elas, sendo que essas relações nem sempre são estáveis no tempo e estão sujeitas às flutuações naturais dos ciclos econômicos.

As séries escolhidas podem ser dependentes de outras variáveis econômicas, algumas delas não totalmente identificáveis; portanto, no caso específico da arrecadação do ICMS, isso pode gerar modelos mal parametrizados.

Mesmo quando identificada uma série variável, poderá haver escassez de dados disponíveis na frequência requerida, o que particularmente ocorre no setor de serviços, como energia elétrica, comunicações e outros, em que os dados são consolidados e podem não alcançar o intervalo exigido para os cálculos.

A estrutura das fontes de receita são sensíveis aos desequilíbrios externos ou cambiais (choques) e a própria arrecadação tem variações não explicadas por fatores econômicos e sim de ordem administrativa ou de política fiscal ou tributária, que podem ser melhor incorporadas com previsões qualitativas.

Os modelos necessitam ser continuamente reparametrizados com base nos dados reais para que possam refletir as tendências, os choques e as mudanças estruturais que eventualmente ocorrem.

2. O ICMS E A PREVISÃO DE RECEITAS

2.1 Histórico do ICMS

O sistema tributário brasileiro em vigor a partir de 1967 operou significativa reforma nos impostos sobre vendas. O antigo imposto, IVC (Imposto sobre Vendas e Consignações), que onerava de forma cumulativa as vendas de mercadorias, foi substituído pelo ICM (Imposto sobre Circulação de Mercadorias), com as características modernas de não cumulatividade e seletividade, incidente sobre o valor agregado em cada etapa de processo de produção e circulação de mercadorias.

Acompanhando a tendência dos países europeus, que em sua maioria adotam o IVA (Imposto sobre o Valor Agregado) como um dos mais importantes impostos de seus sistemas tributários, o Brasil foi o primeiro país a adotar essa modalidade de tributação, no nível estadual (RESENDE,1993).

O ICMS é um imposto sobre o consumo, de base ampla e generalizada, de caráter predominantemente fiscal, ou seja, arrecadatório, e que incide sobre a parcela do valor agregado nas transações econômicas das mercadorias sujeitas ao imposto. É considerado um tributo indireto devido ao contribuinte de fato, ser o adquirente da mercadoria, sobre quem vai recair finalmente o ônus do imposto repassado pelo contribuinte de direito.

É um imposto de arrecadação expressiva, constituindo a principal fonte de recursos próprios dos Estados, com uma participação relativa média de aproximadamente 90% da arrecadação tributária dos mesmos e de 25% da carga tributária bruta dos três níveis de governo. É não-cumulativo por incidir sobre cada etapa da circulação de mercadorias separadamente. Na maioria dos casos as empresas o repassam ao consumidor através dos preços dos produtos.

A Constituição Federal de 1988 (art.153, § 2.º, III) define que o ICMS poderá ser seletivo em função da essencialidade das mercadorias. Assim, para produtos básicos, o imposto cobrado é menor do que para produtos supérfluos. A exceção à regra são os combustíveis e os serviços de energia elétrica e de telefonia, que não obedecem ao princípio da essencialidade; assim como outros que vierem a ser definidos em lei. Ao Senado Federal, mediante iniciativa do Presidente da

República, compete estabelecer as alíquotas aplicáveis às operações e prestações interestaduais, assim como as alíquotas mínimas e máximas nas operações internas.

Considera-se contribuinte do ICMS qualquer pessoa física ou jurídica que realize com habitualidade, ou em volume que caracterize intuito comercial, operações relativas à circulação de mercadorias e as prestações de serviços de transporte interestadual e intermunicipal e de comunicação, ainda que as operações e as prestações se iniciem no exterior. (art. 4º, Lei Complementar nº 87/96).

As principais operações sobre as quais incide o ICMS e cuja ocorrência caracteriza o fato gerador do imposto são as seguintes, conforme o art. 2.º do RICMS/ES (2002):

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 - Fornecimento de mercadorias com prestação de serviços não compreendidos na competência tributária dos Municípios; e

V - Fornecimento de mercadorias com prestação de serviços sujeitos ao imposto sobre serviços, de competência dos Municípios, quando a lei complementar aplicável expressamente o sujeitar à incidência do imposto estadual.

VI - A entrada de bem ou mercadoria importados do exterior, por pessoa física ou jurídica, ainda que não seja contribuinte habitual do imposto, qualquer que seja sua finalidade;

A base de cálculo do ICMS para a maioria das operações é:

- a) O valor da operação ou da prestação do serviço, incluídos os juros, seguros e demais importâncias debitadas ou cobradas dos destinatários das mercadorias ou usuários dos serviços.
- b) O valor total da operação, quando forem fornecidas mercadorias com serviços não compreendidos na competência tributária dos municípios.

O sistema tributário implantado pela Constituição de 1988 ampliou o campo de incidência do ICM, com a eliminação dos impostos únicos então existentes e dos tributos sobre serviços e a incorporação de suas bases ao novo ICMS (Imposto sobre a Circulação de Mercadorias e Serviços),

O ICMS, (previsto no art. 155, II, CF), é atualmente o principal imposto sobre o consumo no Brasil, respondendo por aproximadamente 25% de toda a carga tributária nacional; sendo de competência tributária dos Estados e do Distrito Federal.

As alíquotas, desse imposto são variáveis dentro do território nacional e fixadas de forma independente pelos Estados e pelo Distrito Federal. A legislação atual ainda estabelece a sua cobrança sobre operações e prestações interestaduais, sendo essa alíquota interestadual fixada por resolução aprovada pelo Senado Federal (art. 155 §2º incisos IV e V). No caso da cobrança sobre operações e prestações interestaduais, a arrecadação é dividida entre o Estado em que o bem é produzido e o Estado em que é comercializado. As exceções a essa regra são o petróleo, os combustíveis e a energia elétrica. Casos em que a arrecadação do ICMS destina-se ao estado produtor.

A Lei Complementar 87/96 (Lei Kandir), de 13.9.96, que definiu normas gerais para o ICMS, estabelece que Lei Estadual poderá atribuir a contribuinte do imposto ou a depositário a qualquer título a responsabilidade pelo seu pagamento, hipótese em que o contribuinte assumirá a condição de substituto tributário. A atribuição dessa responsabilidade se dará apenas em relação a mercadorias e serviços previstos em lei de cada Estado. Pelo instituto da substituição tributária verifica-se a transformação de um tributo multifásico por natureza (como é o caso dos tributos sobre valor agregado) em tributo monofásico, isto é, dentre os vários agentes que interferem em determinada cadeia de produção/distribuição, a legislação elege aquele que, por oferecer maior segurança no cumprimento da obrigação tributária, será o sujeito passivo responsável pelo recolhimento de todo o tributo relativo àquela cadeia produtiva, inclusive sobre fatos geradores que devam ocorrer posteriormente.

Seguindo a tendência mundial de desonerar a exportação, a Lei Complementar 87/96 estabelece a não incidência do tributo sobre as operações e prestações que destinem mercadorias ao exterior - inclusive produtos primários e produtos industrializados semi-elaborados - ou serviços. Estabelece ainda o direito de a

empresa creditar-se do imposto incidente sobre as mercadorias e insumos entrados em seu estabelecimento e destinados à integração ou consumo em processo de produção de mercadorias industrializadas, inclusive semi-elaboradas destinadas ao exterior.

Estabelece ainda a desoneração da produção e do investimento, garantindo às empresas o direito de crédito do imposto incidente sobre a entrada de mercadorias destinadas ao uso ou consumo do estabelecimento - inclusive energia elétrica - e sobre bens destinados ao ativo permanente.

2.2 O ICMS no Estado do ES

De acordo com dados do IPEADATA (2009), o Espírito Santo cresce acima da média nacional há várias décadas, e boa parte deste crescimento deve-se ao desempenho das *commodities* (minério de ferro, aço, celulose e, mais recentemente, petróleo e gás). Sabe-se que hoje é um dos Estados com maiores índices de desenvolvimento do Brasil, o que pode ser verificado pelos seus indicadores econômicos e sociais (PIB *per capita*, IDH, etc.), e que a produção de *commodities* foi decisiva neste processo, (GRASSI & CAÇADOR, 2009).

A arrecadação do ICMS no estado do Espírito Santo passou a ocupar a 8ª posição no ranking de arrecadação do país, segundo o Relatório de Gestão da SEFAZ-ES 2003-2006. Essa posição, associada aos dados de estimativas populacionais divulgados anualmente pelo IBGE, colocam o Espírito Santo como o Estado com a maior arrecadação de ICMS per capita do país.

A partir do ano de 2003 foi observado um crescimento vertiginoso da arrecadação do imposto como resultado do emprego de novas tecnologias, reestruturação do modelo de fiscalização, recuperação de créditos, medidas de política de administração tributária, aprimoramento profissional e desenvolvimento gerencial. No período de 2002 a 2006 a arrecadação do ICMS representou em média 93,88% do total da receita tributária do Estado, (Tabela 1), com a receita de R\$ 5,02 bilhões no ano de 2006, representando um aumento real de 6,1% em relação ao ano anterior. No ano de 2007 representou 87% da receita total (tributária e não-tributária) do estado e os setores que mais contribuíram foram principalmente o comércio, as

importações e a indústria, conforme explicou o secretário de fazenda do ES em matéria publicada na seção de economia do jornal A Gazeta, do dia 23/03/2008.

O comércio exterior, com mais de 30% do total arrecadado, foi o que mais contribuiu para o aumento de receita no ano de 2006 e seu crescimento está diretamente relacionado ao estímulo às importações representado pela valorização da moeda nacional e aos benefícios fiscais do programa Fundap, que oferece incentivos fiscais para empresas que efetuarem despachos de importações pelas unidades portuárias sob jurisdição do Estado do Espírito Santo.

A arrecadação sobre combustíveis é a segunda mais significativa com uma participação em 2006 da ordem de 14,58%. Em seguida vêm os setores de telecomunicações e energia elétrica. A evolução da participação desses setores explica-se pelo crescimento induzido pelos novos investimentos no estado e pela descoberta de reservas de petróleo no seu território.

2.2.1 O Sistema Fundap

O Espírito Santo é o quarto maior estado importador do país. O expressivo aumento do comércio exterior brasileiro evidenciado a partir do ano de 1995 e os incentivos proporcionados pelo programa Fundap, explicam a posição ocupada pelo estado nesse setor.

O Fundo para o Desenvolvimento das Atividades Portuárias – Fundap, criado pela Lei nº 2.508, de 22/05/70 e Regulamentado pelo Decreto nº 163-N, de 15.07.71, assegura financiamento para apoio a empresas com sede no Estado e que realizam operações de comércio exterior tributados com ICMS. A gestão dos recursos financeiros do Fundap cabe ao Banco de Desenvolvimento do Espírito Santo S/A - BANDES, e tem como objetivo o incremento e diversificação do intercâmbio comercial com o exterior e a promoção de novos investimentos considerados de interesse para o desenvolvimento econômico e social do estado.

O fato gerador do ICMS nas importações realizadas pelo Fundap fica diferido para o momento em que ocorrer a efetiva saída da mercadoria do estabelecimento importador e o seu recolhimento será efetuado até o 26º dia do mês subsequente àquele em que ocorrerem as operações. Adota-se, como regra geral, a alíquota de

12% (doze por cento) nas operações interestaduais, e de 17% nas operações dentro do próprio Estado.

2.3 Características Estatísticas da Série do ICMS ES

2.3.1 O Gráfico




Gráfico 3: Arrecadação do ICMS de Jan/2000 a Ago/2010

O gráfico 3 apresenta, em escala linear, o comportamento da arrecadação do ICMS-ES em valores correntes mensais para o período de jan/2000 a jun/2010. Pode-se observar uma clara tendência de crescimento, notadamente a partir de jan/2002, indicando uma provável não estacionariedade da série na média. Nos extremos do gráfico destacam-se dois períodos de aparentes choques na variância, sendo o primeiro, entre dez/2000 e jun/2001, devido a prováveis fatores conjunturais e econômicos e o segundo entre dez/2008 e mar/2009, como reflexo da crise financeira internacional iniciada em set/2008, com efeitos observados na arrecadação a partir de dez/2008, quando houve um pico de arrecadação, possivelmente potencializado pelas medidas anti-cíclicas de redução de impostos adotadas pelo governo federal. No mês de março de 2009 observa-se um pico negativo indicando o efeito máximo da crise financeira sobre a arrecadação do ICMS. O intervalo de dez/2008 a março/2009, onde se observa grande variabilidade, caracteriza uma possível mudança estrutural na série, o que sugere a utilização de uma modelagem especial para captar a perturbação localizada e evitar ruídos na

previsão. O crescimento estável ao longo do período de 2002 a 2008 reflete a relativa estabilidade da economia no período, não sendo possível identificar graficamente vestígios de ciclos econômicos que possam afetar significativamente a análise da série no período. Após a queda na arrecadação observada de jan/2009 a mar/2009, volta-se a observar a tendência de retomada do crescimento a partir do mês de abril/2009.

2.3.2 Tendência e Estacionariedade

O filtro de *Hodrick-Prescott* é um método de ajustamento largamente utilizado por macro economistas para a identificação de tendências de longo-prazo em séries econômicas. Esse método foi utilizado pela primeira vez em 1980 para analisar os ciclos de negócios do pós-guerra e consiste no ajustamento da série original em torno de uma tendência média μ , calculada pela minimização da sua variância utilizando a fórmula:


$$\sum_{t=1}^T (y_t - \mu_t)^2 + \lambda \sum_{t=2}^{T-1} ((\mu_{t+1} - \mu_t) - (\mu_t - \mu_{t-1}))^2$$


Gráfico 4: Filtro de Hodrick-Prescott (lambda = 14400)

O gráfico 4 apresenta a separação da tendência dos demais componentes da arrecadação. A análise prévia dos dados mediante o filtro HP constatou a presença de tendência na série, o que já poderia ser inferido do gráfico 3. Como pode ser observado, até o ano de 2002 a receita do ICMS segue um padrão de tendência quase horizontal e a partir de 2003 apresenta uma tendência crescente uniforme. O

comportamento da série no período de 2003 até 2009 sugere uma tendência de crescimento no longo prazo.

Para prosseguirmos na análise da tendência, é de fundamental importância identificar a sua natureza se determinística ou aleatória. Se for determinística, ela é o componente fundamental para descrever o comportamento da série no longo-prazo, ou seja, a importância da correlação dos valores futuros com os valores passados poderia ser minimizada na previsão. Por outro lado, se a tendência apresentar características aleatórias, os valores passados serão fundamentais para a previsão dos valores futuros. Esse fato pode ser caracterizado pela presença de raízes unitárias no termo auto-regressivo da série, (Pindyck; Rubinfeld, 2004).

Utilizaremos o teste da raiz unitária de Dickey-Fuller Aumentado (ADF) para verificação da natureza da tendência, se determinística ou aleatória. Esse teste baseia-se, por razões teóricas e práticas na seguinte fórmula (GUJARATI, 2000, p. 819):

$$\Delta Y_t = \beta_1 + \beta_2.t + \delta.Y_{t-1} + \sum_{i=1}^m \alpha_i.\Delta Y_{t-1} + \varepsilon_i, \text{ onde } \varepsilon_i \text{ é um termo ruído branco.}$$

A hipótese nula é de que $\delta = 0$ para que haja uma raiz unitária. Conforme resultado da tabela 2, o módulo da estatística de teste apresenta um p valor de 10,79%. Logo, não podemos rejeitar a hipótese nula de que existe uma raiz unitária e, portanto, o processo não pode ser considerado estacionário a um nível de significância de 5%.

Tabela 2: Teste de Raiz Unitária para ICMS

Null Hypothesis: ICMS has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 2 (Automatic based on AIC, MAXLAG=12)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.114143	0.1079
Test critical values:			-4.038365	
1% level			-3.448681	
5% level			-3.149521	
10% level				
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(ICMS)				
Method: Least Squares				
Date: 05/10/10 Time: 16:45				
Sample (adjusted): 2000M04 2009M12				
Included observations: 117 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
ICMS(-1)	-0.262289	0.084225	-3.114143	0.0023
D(ICMS(-1))	-0.315540	0.104302	-3.025260	0.0031
D(ICMS(-2))	-0.149551	0.094386	-1.584462	0.1159
C	30740.30	10322.42	2.978013	0.0036
@TREND(2000M01)	1125.399	363.4495	3.095437	0.0025
R-squared	0.259606	Mean dependent var		4024.949
Adjusted R-squared	0.233163	S.D. dependent var		36335.98
S.E. of regression	31819.14	Akaike info criterion		23.61532
Sum squared resid	1.13E+11	Schwarz criterion		23.73336
Log likelihood	-1376.496	F-statistic		9.817685
Durbin-Watson stat	1.945159	Prob(F-statistic)		0.000001

A aplicação do teste da raiz unitária na série após a operação de primeira diferença apresenta resultados altamente significativos, com $t = -11,11$, que em valor absoluto ultrapassa muito valor crítico de $t = -3,45$ para um nível de significância de 5%. O que confirma a estacionariedade, sendo a série do ICMS integrada de ordem um. O gráfico 5 mostra a série estacionária após a transformação realizada.




Gráfico 5: Primeira diferença da série do ICMS

2.3.3 Ciclos e Sazonalidade

O imposto sobre circulação de mercadorias e serviços (ICMS) incide sobre o valor agregado à mercadoria e, portanto, sua arrecadação está diretamente vinculada ao nível da atividade econômica e espera-se que esse imposto seja influenciado pelos ciclos dos negócios. O ciclo dos negócios é um padrão mais ou menos regular de expansão (recuperação) e contração (recessão) da atividade econômica em torno de uma trajetória com tendência de crescimento (DORNBUSCH; FISCHER, 1991).

Os ciclos observados na economia não apresentam regularidades quanto ao tempo nem quanto ao espaço e sua taxa tendencial não é constante, mas varia em função dos diversos fatores que podem alterar a taxa de crescimento da produção. A teoria econômica identifica como distúrbios exógenos mais importantes que alteram o equilíbrio dos ciclos, os choques de produtividade, os choques de oferta e os choques nos gastos do governo, (DORNBUSCH; FISCHER, 1991, p. 805).

O filtro de *Hodrick-Prescott* do gráfico 4 apresenta os componentes cíclicos da série original do ICMS. Ao longo de quase todo o período amostral observa-se oscilações moderadas de baixa amplitude, caracterizando ciclos de curta duração normalmente observados em séries econômicas como resultantes dos inúmeros fatores

conjunturais que podem afetar direta ou indiretamente o resultado da receita tributária. Não sendo possível identificar visualmente indícios de sazonalidade.

A definição de sazonalidade em séries temporais, atualmente aceita de forma generalizada é a de Hylleberg (1992, p.4), segundo a qual sazonalidade é o movimento sistemático, não necessariamente regular, dentro do intervalo de um ano, causado por mudanças do clima, pelo calendário, pelas decisões tomadas e, direta ou indiretamente, pelas decisões de produção e consumo feitas pelos agentes econômicos. Estas decisões são influenciadas pelas dotações, expectativas e preferências dos agentes e pelas técnicas de produção disponíveis na economia.

Essa definição admite que a frequência e a amplitude dos movimentos sazonais podem mudar ao longo do tempo. Destaca também como causas básicas tanto variáveis de natureza mais exógena, menos susceptíveis a mudança ao longo do tempo, como as condições meteorológicas e os efeitos do calendário, quanto as de natureza mais endógena, associadas ao comportamento dos agentes econômicos, cujos hábitos e preferências podem mudar (LOPES, 2007).

Para a identificação do grau de sazonalidade na série do ICMS tornada estacionária após a primeira diferença, foi executada a regressão sobre as onze variáveis *dummies* representativas dos meses de fev a dez, obtendo-se o resultado da tabela 3 abaixo:

Tabela 3: Sazonalidade com Variáveis Dummies

Dependent Variable: DICMS				
Method: Least Squares				
Date: 04/17/10 Time: 15:24				
Sample (adjusted): 2000M02 2009M06				
Included observations: 113 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-6315.889	11161.77	-0.565850	0.5728
D2	-18812.31	15385.43	-1.222735	0.2243
D3	-1905.711	15385.43	-0.123865	0.9017
D4	24893.19	15385.43	1.617971	0.1088
D5	-9900.611	15385.43	-0.643506	0.5214
D6	27020.49	15385.43	1.756238	0.0821
D7	853.0000	15785.12	0.054038	0.9570
D8	18346.00	15785.12	1.162234	0.2479
D9	13310.00	15785.12	0.843199	0.4011
D10	9982.556	15785.12	0.632403	0.5286
D11	21965.22	15785.12	1.391514	0.1671
D12	31014.56	15785.12	1.964797	0.0522
R-squared	0.189084	Mean dependent var	3172.540	
Adjusted R-squared	0.100766	S.D. dependent var	35311.63	
S.E. of regression	33485.30	Akaike info criterion	23.77572	
Sum squared resid	1.13E+11	Schwarz criterion	24.06536	
Log likelihood	-1331.328	F-statistic	2.140949	
Durbin-Watson stat	2.910524	Prob(F-statistic)	0.023718	

Observa-se que todos os coeficientes resultaram não-significativos para um grau de significância de 5% para o intervalo amostral de jan/2000 a dez/2009, de onde se

conclui que a sazonalidade da série do ICMS pode ser considerada desprezível para efeito de modelagem econométrica da série.

2.3.4 Volatilidade

A importância da volatilidade é destacada especialmente na mensuração de incertezas em séries econômicas com maior sensibilidade a choques positivos ou negativos que poderão causar grandes impactos nos valores futuros observados, com repercussão por longos períodos. A volatilidade (variância condicional) está associada a variações referentes ao desvio padrão e é expressa em porcentagem. Na prática, representa uma medida da velocidade do mercado e valioso instrumento para orientação de investimentos e classificação de riscos.

A estacionariedade de uma série em relação à variância pode ser estudada através do processo GARCH, dado pela fórmula (GUJARATI, 2000, p.862):

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2$$

Um processo estocástico GARCH (1, 1), é estacionário se $(\alpha_1 + \alpha_2) < 1$, sendo α_1 e α_2 os coeficientes do quadrado do erro e da variância do período anterior respectivamente. A aplicação do modelo GARCH (1, 1) na primeira diferença da série do ICMS e sob a hipótese nula de normalidade dos resíduos, apresenta coeficientes não-significativos, com $(\alpha_1 + \alpha_2) = 0,445153$, indicando uma volatilidade desprezível e a estacionariedade da série em relação à variância (tabela 4).

Tabela 4: Modelo GARCH (1,1) para a Série DICMS

Dependent Variable: DICMS				
Method: ML - ARCH				
Date: 04/12/10 Time: 14:56				
Sample (adjusted): 2000M02 2009M12				
Included observations: 119 after adjustments				
Convergence achieved after 24 iterations				
Variance backcast: ON				
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
C	5406.574	3467.224	1.559338	0.1189
Variance Equation				
C	8.40E+08	2.71E+08	3.104766	0.0019
RESID(-1)^2	0.380928	0.219107	1.738550	0.0821
GARCH(-1)	0.064225	0.123316	0.520819	0.6025
R-squared	-0.002196	Mean dependent var	3721.731	
Adjusted R-squared	-0.028340	S.D. dependent var	36106.95	
S.E. of regression	36615.01	Akaike info criterion	23.73078	
Sum squared resid	1.54E+11	Schwarz criterion	23.82419	
Log likelihood	-1407.981	Durbin-Watson stat	2.720256	

2.4 A composição da Base Tributária do ICMS

Os incentivos proporcionados pelo Sistema Fundap com o seu efeito de atrair empresas que operam no comércio exterior através dos portos e aeroporto localizados na jurisdição do Estado, tornam a receita proveniente do ICMS sobre operações de importação, a fatia mais significativa da arrecadação do imposto, representando 31,61% do total das receitas do ICMS, conforme Relatório de Gestão SEFAZ-ES 2003-2006, p. 20. O mesmo relatório identifica o setor de combustíveis como o segundo principal componente da receita de ICMS, com 14,58% da arrecadação total desse imposto no ano de 2006.

Dados relativos ao período de janeiro a agosto de 2007 indicam a seguinte composição percentual de receitas: importações 32%, substituição tributária (combustíveis, bebidas, fumo, automóveis e autopeças) 15,46%, indústria 14,28%, comércio 12,25%, energia elétrica 9,30% e comunicações 7,79%, agropecuária 2,6% e transportes 1,98. Juntos esses setores representam mais de 95% da arrecadação do ICMS no Estado do Espírito Santo e são indicadores aproximados da composição da base de incidência do imposto e estão representados no gráfico 6 a seguir:




Gráfico 6: Composição do ICMS-ES, Jan a Ago 2007

Fonte : Valores extraídos do Relatório SEFAZ-ES, agosto/2007. Elaboração do autor.

Dados históricos extraídos do Balancete Geral/SEFAZ-ES (SEFAZ-ES, 2010), do período de jan/1999 a mar/2010 e tabelados pelo IJSN (Instituto Jones dos Santos

Neves), instituição voltada para estudos e pesquisas do governo estadual, apresentam a seguinte composição percentual histórica das receitas do ICMS: Importações 31,1%, Comércio 12,3%, Indústria 12,7%, Energia Elétrica 8,8% e Serviços de Comunicação 7,3% e Serviços de Transporte 1,6%.

A substituição tributária constitui-se num mecanismo de cobrança em que o produtor ou distribuidor da mercadoria é legalmente nomeado como responsável pelo pagamento do imposto e é utilizada notadamente na comercialização de combustíveis, bebidas, fumo, automóveis e autopeças.

Quanto ao setor de energia, a expectativa é de que o crescimento econômico fará crescer fortemente a demanda por energia elétrica no Estado e, por consequência, a arrecadação do ICMS sobre energia elétrica. O Espírito Santo é a unidade da Federação que tem o maior consumo de energia *per-capta* no Brasil, superando o Estado de São Paulo. Os projetos das grandes empresas como Vale, Arcelor Mittal, Samarco, Fibria Celulose e o consumo populacional, são os responsáveis por esse resultado segundo a Secretaria de Estado de Desenvolvimento Econômico e Turismo.

A indústria e o comércio juntos, atualmente são responsáveis por quase 30% da arrecadação e são os setores com maior potencial de crescimento tendo em vista o crescimento econômico experimentado pelo Estado nos últimos anos. Medidas das atividades industriais e comerciais podem ser obtidas pelos índices de produção industrial, índice de vendas totais no varejo disponibilizados nas estatísticas do IBGE referentes ao Estado e pelo INEF, índice do nível de emprego formal do estado, calculado pelo MTE (Ministério do Trabalho e Emprego).

2.5 A Previsão de Receitas no ES

A atividade de previsão de receitas públicas, no contexto de uma economia estável, tem recebido cada vez maior atenção dos gestores públicos. Além da exigência legal com vistas ao equilíbrio fiscal estabelecido pela Lei de Responsabilidade, representa fator imprescindível ao planejamento e aplicação dos recursos públicos.

Não obstante as incertezas inerentes ao ambiente econômico e as dificuldades de identificação de todas as variáveis que influenciam a arrecadação, a utilização de técnicas econométricas, aplicadas aos dados históricos disponíveis, possibilitam a

escolha de um modelo matemático que melhor se ajusta à obtenção de estimativas de receitas mais confiáveis.

Como fatores que influenciam direta ou indiretamente o resultado da arrecadação podemos identificar: as mudanças na legislação, os recolhimentos extraordinários do imposto, programas de recuperação de crédito, crescimento da economia, taxa de inflação, dívida ativa, multas e juros, mudanças na demanda agregada, políticas de governo e outras circunstâncias econômicas.

Particularmente no período de 2002 a 2007, segundo informações do Secretário Estadual de Fazenda do Espírito Santo na época, os fatores que mais influenciaram a receita foram o crescimento da economia, a fiscalização eficaz, o cancelamento de regimes especiais de tributação e o combate à sonegação.

Segundo trabalho de Oliveira (2004), contendo análise da capacidade de investimento do Estado do Espírito Santo no período de 1997/2003, as previsões de receitas adotadas para os diversos elementos da receita estadual são obtidas mediante a análise e projeção das diversas linhas de tendência no tempo. Parte da consideração de que, quaisquer variáveis que apresentem um crescimento cumulativo observado em intervalos constantes de tempo, têm sua trajetória descrita por uma equação do tipo:

$$X_t = a \cdot e^{(b \cdot t)}$$

Onde:

X_t é uma variável qualquer

a = constante

e = base do logaritmo natural

b = taxa de crescimento cumulativa de X_t por unidade de tempo

t = variável tempo (dia, mês, ano)

Os valores dos parâmetros a e b são estimados mediante análise de regressão aplicada aos dados históricos utilizando a seguinte equação linearizada:

$$\ln (X_t) = \ln a + b \cdot t$$

Outros métodos qualitativos de previsão podem ser utilizados para a estimação das receitas futuras do governo. Os métodos qualitativos de previsão se baseiam em conjecturas sobre as entradas futuras. Essas técnicas não fazem uso de ferramentas matemáticas elaboradas e não se valem de especificações rigorosas de hipóteses para o modelo. O método qualitativo de previsão mais usado pelos gestores públicos é o da previsão conjectural. Essa previsão é elaborada por uma ou mais pessoas que dispõem de informações privilegiadas sobre as circunstâncias futuras prováveis da economia local e que fazem uma avaliação dos seus possíveis efeitos sobre a receita a ser prevista. Entre os fatores conjunturais que podem afetar a arrecadação do ICMS podemos listar as alterações nos valores das alíquotas, diferença de alíquotas interestaduais, nível de atividade econômica, programas de fiscalização, implantação ou cancelamento de regimes especiais, realização de dívida ativa, efeito climático e outros.

Embora sem rigor matemático, essas previsões podem ser satisfatórias se realizadas por pessoas experientes mesmo quando o ambiente econômico apresenta instabilidade. Em tais circunstâncias os métodos quantitativos são inadequados para modelar as alterações que se processam no padrão histórico da variável.

Conforme entrevista com o ex-secretário de fazenda do Estado do Espírito Santo, para a estimativa inicial do crescimento da arrecadação do ICMS, um dos métodos utilizados consistia em tomar por base o crescimento do PIB nacional, o que fornece uma projeção conservadora das receitas, considerando que as taxas de crescimento do PIB estadual mostraram-se superiores à taxa do país na última década.

A previsão do ICMS mediante a curva exponencial logarítmica fornece o seguinte resultado apresentado no gráfico 7, onde se observa que a previsão superestima o valor da arrecadação para o período de jan 2010 a ago/2010, com o valor do EPAM igual a 30,82%, demonstrando a inadequação desse modelo para previsões do ICMS do estado do Espírito Santo e a necessidade do estudo de formas alternativas mais precisas.




Gráfico 7: Previsão do ICMS com modelo exponencial logarítmico.

Ribeiro (2009), em trabalho realizado para o Instituto Jones dos Santos Neves, fornece uma metodologia com base em modelos econométricos, para projetar as receitas de ICMS do Estado do Espírito Santo. Utilizou 130 dados mensais e mais de 30 dados trimestrais no período de 1999 a 2009 para comparar três tipos distintos de metodologias de estimação. Os modelos da classe ARIMA, os modelos estruturais com defasagens da própria receita de ICMS com produção industrial, vendas no varejo e importações como variáveis explicativas e modelos estruturais estimados por *Dynamic Ordinary Least Squares* (DOLS). Todos os modelos foram avaliados em duas frequências de dados, mensais e trimestrais. Os resultados obtidos sugerem que os modelos trimestrais dominam estritamente os modelos mensais e que o melhor modelo dentre todos os apresentados é aquele, estimado por MQO (Mínimos Quadrados Ordinários), que define a receita de ICMS corrente como função da receita de ICMS defasada, da produção industrial defasada e do comércio defasado, todos por um trimestre.

2.6 Trabalhos no Brasil

A utilidade da previsão de receitas fiscais para fins de planejamento, pressupõe a existência de uma moeda estável, um ambiente com inflação controlada e um mínimo de previsibilidade das variáveis que influenciam a arrecadação. Essas condições só se tornaram realidade no Brasil a partir de 1994 com a reforma monetária que criou o real. A partir de então, e especialmente depois da Lei de

Responsabilidade Fiscal, que tornou obrigatória a previsão de receitas pelos entes públicos, observam-se no Brasil vários trabalhos sobre o tema, dentre os quais destacamos os seguintes:

No trabalho de Arraes e Chumvichitra (1996) são feitas previsões de curto prazo utilizando a série trimestral do ICMS do estado do Ceará no período de 1970 a 1995. São comparadas as previsões do modelo auto-regressivo puro com o modelo ARIMA e obtidos os seguintes resultados. Para a estimação com o modelo auto-regressivo, para cada trimestre foi escolhido o modelo de melhor desempenho na previsão da arrecadação, tendo a projeção do ICMS anualizada com base nos valores trimestrais, apresentado um erro acumulado de 3,5%. Quanto ao modelo ARIMA ($p,1,0$), o trabalho conclui que após a extração do efeito sazonal mediante a operação de diferenças, estes modelos apresentaram melhores previsões que as geradas pelos modelos auto-regressivos.

Para análise das séries do imposto de renda, no período de julho de 1994 a dezembro de 2000, Melo (2001) propõe o emprego das metodologias ARIMA, de *Box-Jenkins* e alisamento exponencial de Holt-Winters sazonal aditivo, como metodologias alternativas para previsão da receita de tributos federais. Conclui que ambos os modelos geraram previsões mais acuradas que a resultante dos modelos de indicadores utilizados pela Receita Federal do Brasil. As estimativas de arrecadação para o período de janeiro a dezembro de 2000 foram obtidas com a redução do erro de previsão médio de 10% para 0,17%.

Pecequini (2001) realizou comparações para avaliar diferentes metodologias de previsão aplicadas à série histórica de arrecadação do ICMS do estado de São Paulo abrangendo o período de janeiro de 1995 a dezembro de 1999, o que resultou na obtenção de quatro previsões em bases mensais e anuais. O primeiro método utilizado é o modelo aritmético convencional, em que os crescimentos dos PIB nacional e estadual são tomados como base para aproximar o crescimento da base tributável do ICMS. Foram utilizados também os métodos da linha de tendência, o método da decomposição clássica e método auto-regressivo ARIMA, para projetar a arrecadação para o ano 2000. Na decomposição clássica foram levadas em consideração variáveis explicativas extraídas de análise para identificação dos setores mais significativos que compõem a base tributária do ICMS paulista, com base em dados governamentais, da indústria e do comércio. Em seguida foi avaliada

a qualidade de cada uma das previsões. Para a previsão de receitas anualizadas, todos os métodos empregados mostraram-se satisfatórios com um desvio relativo máximo (EPAM) de 3,1%. Quanto às previsões mensais, com exceção do método convencional, os demais foram considerados adequados com ocorrências de desvios relativos inferiores a 5%. O trabalho conclui destacando que o modelo da decomposição clássica da série temporal é o que melhor se ajusta às séries analisadas, embora apresente a desvantagem de exigir variáveis explicativas confiáveis.

Siqueira (2002) utiliza a modelagem ARIMA para analisar dez séries de tributos federais no período de janeiro de 1989 a dezembro de 2000 e faz a comparação das previsões com a arrecadação de 2001 mediante a raiz quadrada do erro quadrático médio de previsão. Conclui que, o modelo Box-Jenkins escolhido se mostra superior aos métodos dos indicadores utilizados na previsão dos tributos federais. Afirma ainda que, as características particulares de cada tributo condicionam a escolha da metodologia mais adequada para a análise ao observar que, para duas das dez séries analisadas o método dos indicadores apresentou previsões estatisticamente mais confiáveis, devido provavelmente às influências que não foram devidamente capturadas pelo modelo ARIMA. Por fim observa que os modelos dinâmicos, em casos específicos, podem melhorar as previsões feitas pelos modelos ARIMA, que apresentam melhores resultados no curto prazo.

Em dissertação apresentada por Corvalão (2002), utilizando a série da arrecadação do ICMS do estado de Santa Catarina de jan/1995 a dez/2002, é proposta uma metodologia mais abrangente para a previsão de receitas, com a utilização de modelo econométrico dinâmico baseado nos conceitos de cointegração e modelo de correção de erros, empregando a abordagem de Hendry, do geral para específico. Para melhorar a acurácia foram incorporadas ao modelo econométrico geral, variáveis explicativas obtidas da participação dos grandes setores econômicos na formação da arrecadação do ICMS e filtradas num processo de reduções sucessivas até a obtenção do modelo final.

O resultado reportado indica que os valores obtidos pelo modelo dinâmico com incorporação de MCE (mecanismo de correção de erros) tiveram um melhor ajustamento do que o modelo ARMA (1,1) utilizado anteriormente; com 2,519% de

EPAM (erro percentual absoluto médio), que é significativamente melhor que os demais trabalhos citados na pesquisa.

Liebel (2004), em abordagem mais ampla do tema, aplica os principais modelos de *forecasting* para a previsão da receita gerada pelo ICMS do estado do Paraná, e elabora um método de trabalho estruturado para aplicação no contexto das receitas tributárias, destacando a importância da previsão qualitativa mediante a análise e consideração de informações sobre eventos de natureza econômica, financeira ou fiscal que possam implicar em variações no resultado da arrecadação. O período de estudo abrange janeiro de 1997 a dezembro de 2003 e foram analisadas séries com amplitudes de 36, 48, 72 e 84 observações. Para a série de 84 o modelo de Winters aditivo resultou em um erro médio percentual de $-0,1\%$; para a série de 72 o modelo de Winters aditivo resultou em um erro médio percentual de $0,4\%$; para a série de 48 o modelo de Winters multiplicativo resultou em um erro médio percentual de $0,1\%$ e para a série de 36 foi escolhido o modelo de alisamento exponencial de Holt com erro médio percentual de $-0,7\%$.

Na previsão da arrecadação do ICMS do estado da Bahia, Marques e Uchoa (2006) destacam que os modelos tradicionais de previsão utilizados, que usam o PIB como variável explicativa, são viesados e apresentam estimadores ineficientes tendo em vista que, as observações do PIB são anualizadas e além de incorporarem sazonalidades, não coincidem com a base tributária do ICMS, por possuir este uma base de incidência de difícil observação. Para substituir o modelo utilizado na Bahia, que além da estimativa do PIB incorporava adicional de produtividade da máquina fiscal, foi proposto o método baseado nos modelos ARMA univariados, que não fazem uso do PIB como regressor. Após utilizar os dados da série deflacionada da arrecadação no período de jul/1994 a mar/2006, o melhor modelo ARMA ajustado projetou um crescimento de receita da ordem de $8,51\%$ contra os $9,54\%$ observados. Portanto, com um erro percentual absoluto médio de $1,03\%$ para o período considerado.

Santos e Costa (2008) discutem especificamente a aplicação dos métodos de alisamento exponencial simples, duplo e sazonal de Holt-Winters à série do ICMS do estado do Maranhão com o objetivo de realizarem previsões mensais do imposto para o ano de 2008. Na busca desse objetivo e comparando os resultados da previsão *ex-post* através da verificação do erro percentual absoluto médio,

concluíram que a técnica do alisamento exponencial sazonal de Holt-Winters aditivo, com erro médio de 8,56%, mostrou-se superior ao modelo de alisamento exponencial de Holt-Winters multiplicativo, com erro médio de 8,61%. Nesse trabalho sugerem a utilização de modelos estocásticos de séries temporais. Mais precisamente os modelos sazonais de Box-Jenkins (ARIMA ou SARIMA), já que os mesmos, de acordo com a literatura, fornecem resultados mais acurados. Também indicam o emprego da combinação dos dois resultados de previsão, pois afirmam que a previsão com modelos combinados, apresenta erros menores e, portanto, são mais precisas, quando comparadas com as duas anteriores.

Campos (2009), em trabalho de abrangência regional, aplicou metodologias de modelos dinâmicos univariados e multivariados para a análise de três séries mensais da arrecadação, relativas ao Imposto de Importação (II), Imposto Sobre a Renda das Pessoas Jurídicas (IRPJ) e Contribuição para o Financiamento da Seguridade Social (COFINS), tributos de competência federal.

Os resultados foram comparados entre si, por meio da raiz quadrada do erro médio quadrático de previsão (RMSE) e comparados com a modelagem ARIMA e com o método dos indicadores, utilizado pela Secretaria da Receita Federal do Brasil (RFB). Considerados os melhores modelos de cada série, foi alcançada a redução média do RMSE de 42% em relação ao erro cometido pelo método dos indicadores e de 35% em relação à modelagem ARIMA, além da drástica redução do erro anual de previsão.

2.7 Metodologia

2.7.1 A Base de Dados

O levantamento de informações referentes à arrecadação é de suma importância para qualquer estudo de *forecasting*. Os dados coletados servirão de ponto de partida para as análises necessárias à identificação do comportamento da série estudada e também são fundamentais para a posterior avaliação da precisão dos modelos estimados, para a escolha daquele que satisfaz os critérios estatísticos estabelecidos e é mais adequado para representar o verdadeiro comportamento da série e a elaboração de previsões.

Os dados de séries temporais utilizados neste trabalho foram obtidos junto aos seguintes órgãos governamentais, em seus respectivos portais na internet e atualizados ao longo do ano de 2010. Comissão Técnica Permanente do ICMS (COTEPE/ICMS) do Conselho Nacional de Política Fazendária (CONFAZ), Secretaria de Estado da Fazenda do Espírito Santo (SEFAZ-ES), Instituto Brasileiro de Geografia e Estatística (IBGE), Banco Central do Brasil (BCB), Agência Nacional do Petróleo (ANP) e Ministério do Trabalho e Emprego (MTE).

A série histórica da arrecadação do ICMS, a mais importante do trabalho, está disponível nos portais do CONFAZ, do BCB e da SEFAZ-ES. Optou-se pela série disponibilizada pelo CONFAZ por apresentar os mesmos valores da série do Banco Central do Brasil e por possuir metodologia mais consistente de totalização da arrecadação apropriada por cada Estado, considerando as complexas operações interestaduais que antecedem o recolhimento do imposto.

O Convênio S/Nº, de 15 de dezembro de 1970, foi o marco inicial de criação de um Sistema Nacional Integrado de Informações Econômico-Fiscais – SINIEF, objetivando a implantação de um sistema básico e homogêneo das estatísticas necessárias à formulação de informações econômico-fiscais. Esse sistema é gerenciado pelo CONFAZ (Conselho Nacional de Política Fazendária).

As séries em estudo abrangem o período amostral de jan/2000 a dez/2009, sendo importante a inclusão deste último ano por apresentar sinais claros da recuperação da economia após a crise financeira do final de 2008. A periodicidade é mensal e totalizam 120 observações, suficientes para atender os critérios mínimos exigidos pelos métodos de previsão utilizados. Os resultados da arrecadação do ano de 2010 serão utilizados para a avaliação das previsões *ex-post* dos modelos. Considerando a natureza dos dados das séries explicativas, por se tratarem de índices econômicos e uma série com valores nominais em dólares, optou-se pela utilização da série nominal do ICMS para a obtenção de previsões também nominais. A verificação da consistência dessa escolha pode ser avaliada pela manutenção das relações de cointegração entre as séries.

Para a análise da composição da arrecadação, foram obtidas informações do relatório gerencial mensal da SEFAZ-ES (SEFAZ-ES, 2007) e do relatório de gestão do governo do Estado do Espírito Santo (SEFAZ-ES, 2003-2006) que apresenta o

perfil da base tributária do ICMS por setores da economia e informações sobre os maiores contribuintes dos impostos estaduais.

Foram consultados, também, trabalhos publicados pela Secretaria de Fazenda Estadual e obtidas informações complementares com o ex-Secretário Estadual de Fazenda do Espírito Santo no período de 2003 a 2008, em entrevista concedida ao autor do trabalho em 09/03/2010.

2.7.2 Descrição das Variáveis

Para compor a equação que, por hipótese, representará o comportamento econômico da formação de receitas do ICMS no Espírito Santo, foram selecionadas as seguintes séries de dados históricos como variáveis exógenas do modelo, obtidas dos portais do Banco Central do Brasil (BCB), do Instituto Brasileiro de Geografia e Estatística (IBGE), da Agência Nacional do Petróleo (ANP) e do Ministério do Trabalho e Emprego (MTE), nos respectivos endereços abaixo:

<https://www3.bcb.gov.br/sgspub/localizarseries/>

http://www.ibge.gov.br/series_estatisticas/

<http://www.fazenda.gov.br/confaz/>

<http://www.anp.gov.br>

<http://www.mte.gov.br>

VIMP - Série temporal mensal do valor total das importações de bens, em US\$ (mil), realizadas pelo Estado do Espírito Santo. Disponibilizadas pelo MDIC/Secex, Secretaria de Comércio Exterior do Ministério do Desenvolvimento Indústria e Comércio e acessadas no portal do Banco Central do Brasil.

O setor de comércio exterior contribui para a formação de aproximadamente 30% da receita total do ICMS, de acordo com relatórios de arrecadação da SEFAZ-ES. Esse fato é explicado pelos incentivos fiscais dados pelo governo estadual através do Sistema Fundap, com redução da alíquota do ICMS para 12% e o diferimento do recolhimento do imposto para o 26º dia útil do mês subsequente à saída do produto do estabelecimento do importador, conforme a legislação pertinente. Dessa forma a teoria econômica sugere que o efeito das importações sobre a arrecadação seja defasado de um período.

IVVAR – Índice do volume de vendas total no varejo para o Estado (2003=100).
Engloba a venda no varejo de todos os setores da economia. Fonte: IBGE.
Acesso pelo portal do Banco Central do Brasil.

O tributo em estudo incide sobre o valor agregado do bem ao longo de toda a sua cadeia produtiva, sendo o consumidor final quem suporta de fato o ônus tributário, que se realiza com a venda do produto no varejo. Para a maioria dos produtos sujeitos ao imposto, este é integralizado no momento da venda para o consumo. Esse mecanismo de arrecadação torna o comércio varejista um expressivo setor na formação da receita do imposto; da ordem de 15%. Essa participação tende a aumentar com o desenvolvimento econômico e a melhoria do IDH associado à população do Estado, pelo fato do consumo das famílias ser diretamente proporcional ao seu nível de renda.

IPIND – Índice do nível de produção industrial do ES (2003=100). Fonte: IBGE.
Acesso pelo portal do Banco Central do Brasil.

Não obstante a sua tardia industrialização em relação a outras regiões mais desenvolvidas do país, o Estado do Espírito Santo experimentou significativo crescimento industrial nas décadas de 70 e 80, motivadas pela implantação de grandes projetos de siderurgia, celulose e a descobertas de jazidas de petróleo. Hoje o Estado conta com uma diversidade de pólos industriais induzidos por esses grandes projetos, com destaque para segmentos de processamento de minério de ferro (pelotas de minério), metalurgia básica, exploração de gás e petróleo, e também na produção destinada à exportação. O setor industrial vem mostrando taxas de crescimento superiores às observadas nos demais estados e a participação do setor no ICMS hoje, é de aproximadamente 15% com tendência de crescimento à medida que são instalados novos projetos industriais.

IVABF – Índice de vendas no varejo de alimentos, bebidas e fumo (2003=100).
Fonte: IBGE.

VPET – Volume (m³) total de vendas de derivados do petróleo por distribuidoras para o ES. Fonte: ANP (Agência Nacional do Petróleo).

VDIE – Volume (m^3) de vendas de óleo diesel por distribuidoras para o ES. Fonte: ANP. (Agência Nacional do Petróleo).

VGAS – Volume (m^3) de vendas de gasolina por distribuidoras para o ES. Fonte: ANP. (Agência Nacional do Petróleo).

Expressiva fonte de receita do ICMS, em torno de aproximadamente 16%, é proveniente do mecanismo de cobrança do imposto denominado substituição tributária, que consiste na determinação legal de responsabilizar o produtor ou o distribuidor pelo recolhimento integral do imposto antes da sua comercialização final. É utilizada para mercadorias que tradicionalmente são vendidas no varejo, como combustíveis, bebidas e fumo, que seriam de difícil acompanhamento e controle fiscal e também para automóveis e auto-peças. Os relatórios de arrecadação disponibilizados pela SEFAZ-ES indicam a empresa Petrobrás S/A como o maior contribuinte do imposto no Estado e esse fato é refletido diretamente na receita de substituição tributária. A série variável VPET, disponibilizada pela Agência Nacional do Petróleo (ANP), consolida o volume em m^3 de todas as vendas de derivados do petróleo para o Estado e, pelos motivos descritos, apresenta-se como uma variável natural para inclusão no modelo de teste.

O imposto incidente sobre bebidas, fumo e alguns produtos de luxo, contribui significativamente para a receita por substituição tributária devido ao princípio da seletividade do imposto, que onera com alíquotas maiores aqueles produtos considerados não essenciais ou supérfluos. O Instituto Brasileiro de Geografia e Estatística (IBGE) disponibiliza a série dos índices agregados de vendas no varejo de alimentos, bebidas e fumo para o ES.

Tendo e vista a diversidade de produtos derivados do petróleo comercializado pelas distribuidoras e a variação nas quantidades destinadas ao ES, algumas séries estatísticas para produtos individuais como gasolina ou óleo diesel, poderão apresentar menor ou maior correlação com a variável endógena a ser pesquisada (ICMS). Possíveis inconsistências nessa correlação podem ser explicadas por omissão dos dados efetivos de vendas e pelo fato do consumo do produto ter relação direta com o índice de atividade econômica, como é o caso do óleo diesel, visto que seu consumo está associado à logística que sustenta o desenvolvimento. Portanto, a série estatística do volume da venda de óleo diesel para distribuidoras no

ES, VDIE, poderá ser utilizada para teste no modelo, assim como o volume de gasolina VGAS.

INEF – Índice do nível de emprego formal do estado do Espírito Santo. Fonte: MTE (Ministério do Trabalho e Emprego)

Conforme levantamento mostrado no Gráfico 1, 25% da arrecadação do ICMS pode ser atribuída a outros setores ou serviços não aferidos, por motivo da não disponibilidade de séries históricas mensais para o período amostral do estudo. Dentre esses setores destacam-se o setor primário, representado pela produção agropecuária, os serviços de transporte, energia elétrica e de telecomunicações. Como variável *proxy* para representar esta parcela da arrecadação será utilizado o Índice do Nível de Emprego Formal do ES – INEF, produzido pelo Ministério do Trabalho e Emprego, disponível nas séries históricas do portal do Banco Central do Brasil e que reflete o aquecimento do mercado de trabalho no Estado.

No gráfico 8, são apresentadas graficamente as séries descritas acima:




Gráfico 8: Gráficos das séries variáveis descritas

2.7.3 Modelos Propostos

Visando a uma maior objetividade e aprofundamento na análise do problema proposto e considerando as conclusões de pesquisas anteriores sobre o tema, foram

selecionadas apenas três classes de modelos para estimação das previsões. Os modelos de Alisamento Exponencial de Holt-Winters, o modelo de Box-Jenkins e um modelo econométrico causal dinâmico.

Os dois primeiros foram escolhidos por permitirem a análise de séries temporais que apresentam tendência e sazonalidade nos dados, tendo em vista que as séries utilizadas apresentam visualmente tendências e aparentes sazonalidades em seus gráficos; características comuns em dados econômicos financeiros temporais. Em adição a esses modelos foi elaborado um modelo de análise de intervenção para medir a significância do efeito da crise financeira de 2008 na arrecadação do ICMS.

Para a especificação do modelo econométrico foi empregada, inicialmente, a modelagem econométrica tradicional de regressão múltipla (GUJARATI, 2000), para a definição da equação geral contendo as variáveis explicativas que, depois de submetidas ao teste de causalidade e aos critérios de significância estatística, se revelaram aptas a integrar o modelo. Em seguida, o mesmo foi expandido com introdução de defasagens para captar a dinâmica do processo e depois reduzido empregando-se a metodologia do geral para o específico, de Hendry. Ao modelo final de longo prazo foi aplicado o mecanismo de correção de erros para a obtenção da equação de curto prazo (ENGLE; GRANGER, 1991).

A escolha de metodologia mista justifica-se pelo fato de existir apenas uma variável endógena de interesse, ou seja, uma variável dependente identificada com base nos relatórios de arrecadação e na teoria econômica que envolve o processo de formação das receitas do imposto, a qual é composta de receitas oriundas dos diversos setores da economia integrantes do campo de incidência do ICMS. Outro fator que condicionou a utilização de várias metodologias é que a maioria das variáveis explicativas são cointegradas com a variável dependente, podendo-se assim aplicar o mecanismo de correção de erro para previsões de curto prazo, muitas vezes não satisfeitas com a utilização de equações de longo prazo.

Para o estudo da dinâmica do processo de formação da receita, foi analisada a estrutura de defasagens de cada variável conforme Johnston e DiNardo (1997) e construída a matriz de correlação das variáveis para avaliar a relevância de cada uma no modelo.

A metodologia clássica, além da consistência teórica do modelo, utiliza o princípio da parcimônia, cujo conteúdo é assim definido por Friedman (1953): “Isto significa que devemos introduzir no modelo algumas variáveis-chaves que capturem a essência do fenômeno em estudo, relegando para o termo de erro u_t , todas as influências secundárias e aleatórias.”

O modelo a ser proposto consiste na seguinte equação:

$$ICMS_t = F(VIMP_t, IPIND_t, IVVAR_t, VPET_t, IVABF_t, VDIE_t, VGAS_t, INEF_t).$$

Considerando, por hipótese, que todas as séries sejam cointegradas, ou seja, que uma combinação linear delas apresente um modelo econometricamente estável, esse modelo poderia ser adotado como função de longo prazo do ICMS.

Cada série explicativa será submetida a testes para detectar a presença de raízes unitárias e o grau de integração entre elas. A verificação da presença de relações de cointegração entre as séries permitirá a elaboração de um modelo para previsões de curto prazo, baseados na teoria de Engle e Granger (1987).

O modelo econométrico de longo prazo identificado, com a inclusão das variáveis explicativas defasadas na equação acima, poderá ser reduzido no processo de modelagem até a forma que atenda aos critérios estatísticos satisfatórios para a previsão com a utilização de metodologia do geral para específico.

2.7.4 Tratamento dos Dados

Para o tratamento dos dados, assim como para a análise e cálculo das regressões será utilizado o software econométrico *EViews 5.1*. Os modelos serão estimados mediante o método dos mínimos quadrados ordinários (MQO), supondo que as variáveis e o termo de erro satisfazem às hipóteses subjacentes ao emprego desse método. Gujarati (2000, p.744) observa que na estimativa de modelos pela metodologia Box-Jenkins, às vezes teremos que recorrer a métodos de estimativa não-linear nos parâmetros; tarefa rotineiramente efetuada por softwares de estatística.

Preliminarmente serão observados os seguintes procedimentos nas variáveis. Estabilização da variância das séries mediante a aplicação da função logarítmica natural. Análise das possíveis restrições sobre os coeficientes, tais como sinal e

valor, de acordo com o esperado pela teoria econômica e tributária. Obtenção da matriz de correlação das series defasadas até a defasagem doze para identificar a dinâmica do processo a ser retratado no modelo.

A comparação da eficiência dos modelos será feita utilizando o EPAM (Erro Percentual Absoluto Médio) que representa a percentagem do erro médio da previsão (MAPE – Mean Absolute Percentual Error). Uma medida de precisão independente de escala e, portanto, adequada para comparar séries de qualquer tamanho e de diferentes tipos de dados. Essa avaliação foi adotada pelo fato de representar uma medida global de erro, atender aos requisitos mais importantes definidos para esse tipo de medida e por ser facilmente calculada, apresentada e entendida. Uma avaliação das várias medidas de acurácia pode ser encontrada em Hyndman & Koehler (2006).

3. REFERENCIAL TEÓRICO

3.1 Métodos Quantitativos de Previsão

As técnicas de previsão podem ser divididas em duas grandes categorias: qualitativas e quantitativas. As técnicas qualitativas geram modelos subjetivos ou intuitivos e são firmados na opinião de especialistas, gerentes ou administradores a partir de informações disponíveis sobre o assunto. As técnicas quantitativas são formadas por modelos matemáticos tais como médias móveis, projeção de linha de tendência, decomposição, regressão, alisamento exponencial, Box-Jenkins e outros. Os modelos quantitativos podem ser divididos em modelos de séries temporais e modelos causais. Os modelos de séries temporais utilizam dados passados como base para a previsão de resultados futuros enquanto que os modelos causais partem do princípio de que o resultado futuro é diretamente influenciado por outros fatores previsíveis e identificados com o auxílio de alguma teoria. Se for usada a teoria econômica, são chamados de modelos econométricos.

Para a pesquisa do modelo para o ICMS do estado do Espírito Santo neste trabalho, serão pesquisados o modelo de alisamento exponencial, o modelo de Box-Jenkins e o modelo causal dinâmico com mecanismo de correção de erros. Os dois primeiros são modelos que utilizam o comportamento da própria série para identificar os padrões estatísticos subjacentes e então projetá-los no modelo de previsão. Esta abordagem tem a vantagem de não utilizar variáveis explicativas exógenas e, portanto, não há a propagação dos erros dessas variáveis no modelo. São menos complexos e particularmente úteis nas previsões de curtos e médios prazos. O modelo causal dinâmico utiliza a teoria econômica para identificar séries temporais que tenham uma relação causal com a série em estudo para então pesquisar o modelo matemático de previsão adequado de acordo com os critérios estatísticos adotados.

3.1.1 Modelo de Alisamento Exponencial de Holt

O propósito dos métodos de alisamento exponencial é distinguir o padrão de qualquer ruído que possa estar contido nas observações e então usar esse padrão para prever valores futuros da série, (MORETTIN; TOLOI, 2006). A grande

popularidade atribuída aos métodos de alisamento é devida à simplicidade, eficiência computacional e à sua razoável precisão.

O Modelo de Alisamento Exponencial Simples é uma média ponderada que dá pesos maiores às observações mais recentes, eliminando as desvantagens do método de média móvel simples, (MORETTIN; TOLOI, 2006). Pode ser descrito matematicamente por:

$$\bar{X}_t = \alpha.X_t + (1-\alpha).\bar{X}_{t-1}, \quad X_0 = X_1, \quad t = 1, \dots, N$$
$$\text{ou} \quad \bar{X}_t = \alpha.X_t + \alpha.(1-\alpha).X_{t-1} + \alpha.(1-\alpha)^2.X_{t-2} + \dots$$

Onde $\bar{X}_t$ é o valor exponencialmente alisado e $0 \leq \alpha \leq 1$ é a constante de alisamento.

O modelo supõe que não há tendências ou qualquer padrão sazonal. É uma média móvel das previsões, corrigidas pelos erros observados em previsões precedentes. A previsão dos valores futuros é dada pelo último valor exponencialmente alisado. Quanto menor for o valor de α mais estáveis serão as previsões finais. O valor de α deve ser especificado de modo a refletir a influência das observações passadas nas previsões. Valores pequenos produzem previsões que dependem de muitas observações passadas. Por outro lado, valores próximos de um levam a previsões que dependem das observações mais recentes e no caso extremo $\alpha = 1$, a previsão é simplesmente a última observação. O software *EViews* no entanto, encontra rapidamente o valor de α que minimiza os erros das previsões.

Esse modelo foi utilizado com bons resultados por Melo (2001) para a previsão de receitas baseados nas séries do imposto de renda.

A principal desvantagem é a dificuldade de determinar o valor mais apropriado da constante de alisamento que pode ser estimada a partir dos dados e o critério utilizado é a minimização da soma de quadrados dos erros de previsão.

Caso a série temporal apresente tendência, o modelo simples fornece previsões que subestimam (ou superestimam) continuamente os valores reais conforme observam Morettin e Toloi (2006).

Holt (1957) estendeu o modelo simples para permitir a previsão para dados com tendência. O modelo de Holt possui duas constantes de alisamento α e β (com

valores entre zero e um), para o nível da série e para a tendência respectivamente, e três equações, (MAKRIDAKIS *et. al.*, 1998):

$$\begin{aligned}L_t &= \alpha.Y_t + (1 - \alpha).(L_{t-1} + T_{t-1}) \\T_t &= \beta.(L_t - L_{t-1}) + (1 - \beta).T_{t-1} \\F_{t+m} &= L_t + m.T_t\end{aligned}$$

Onde L_t representa o nível estimado da série no tempo t , T_t a tendência estimada e F_{t+m} é a previsão do valor da série para m períodos à frente.

A desvantagem principal é a dificuldade em determinar os valores mais apropriados das duas constantes de alisamento α e β , (MORETTIN; TOLOI, 2006).

Na hipótese de presença de tendências na série, o parâmetro α pode ser adaptado para forma descrita como modelo de Holt. O nível da série é estimado como uma função do valor real da série no tempo t , do nível da série no tempo precedente e da tendência estimada no tempo precedente. A tendência no tempo t é estimada como uma função do valor “alisado” da mudança no nível entre os dois períodos de tempo e a tendência estimada para o período de tempo precedente. Seguindo a exposição encontrada em Cirincione *et al.*(1999), a previsão no tempo t para m períodos futuros é igual ao nível da série em t mais o produto de m pela tendência no tempo t . Modelos dessa natureza já foram utilizados na previsão de receitas tributárias federais e apresentaram bons resultados, conforme se pode observar no trabalho de Melo (2001) para o caso das séries do Imposto de Renda.

3.1.2 Modelo de Alisamento Exponencial Sazonal de Holt-Winters

Para séries temporais que apresentem um comportamento mais complexo, com tendência e padrões sazonais, os modelos de alisamento exponencial simples e de Holt, não são apropriados, a menos que a série seja primeiro desazonalizada.

O método de Holt foi estendido por Winters (1960) para capturar diretamente a sazonalidade. Essa modelagem de Holt-Winters é baseada em três equações que ajustam o nível, a tendência e a sazonalidade, respectivamente. A sazonalidade pode ser tratada na forma aditiva ou multiplicativa conforme o padrão observado na série. A maioria das séries econômicas com presença de sazonalidade exibe um padrão multiplicativo, sendo este o modelo mais usual.

As equações básicas para o modelo multiplicativo de Holt-Winters são as seguintes, (MAKRIDAKIS *et. al.*, 1998):

$$L_t = \alpha \cdot \frac{Y_t}{S_{t-s}} + (1 - \alpha) \cdot (L_{t-1} + T_{t-1})$$

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot T_{t-1}$$

$$S_t = \gamma \cdot \frac{Y_t}{L_t} + (1 - \gamma) \cdot S_{t-s}$$

$$F_{t+m} = (L_t + m \cdot T_t) \cdot S_{t-s+m}$$

As desvantagens são as dificuldades em determinar os valores mais apropriados das constantes de alisamento e de estudar as propriedades estatísticas, tais como média e variância de previsão e, conseqüentemente, construção de um intervalo de confiança. A determinação das constantes de alisamento (α , β , γ) é realizada de modo a tornar mínima a soma dos quadrados dos erros de ajustamento, (MORETTIN; TOLOI, 2006).

Este modelo adapta o método de Holt para incluir um componente sazonal, em adição aos componentes de nível e de tendência. A primeira variante do modelo é aditiva. Supõe-se, inicialmente, que a sazonalidade é constante ao longo da série que está sendo prevista e independe da taxa de crescimento da série. A variante multiplicativa deste modelo supõe que a sazonalidade está mudando ao longo da série e o termo que representa a variação periódica possui comportamento estatístico proporcional à taxa de crescimento da série. Ao incorporar a sazonalidade, aumenta-se, naturalmente, a necessidade de inclusão de mais dados. Diversas séries tributárias apresentam comportamento bastante sazonal e a adoção desta metodologia pode melhorar significativamente a precisão das previsões. Esse é precisamente o caso das séries do Imposto de renda do IPI e da CPMF, por exemplo.

Melo (2001) demonstrou que a utilização desta metodologia poderia fornecer resultados de previsão mais precisos que o método de indicadores utilizado pela SRF, se for considerado o caso específico da arrecadação de impostos sobre a renda de pessoa física (IRPF) e de pessoa jurídica (IRPJ).

3.1.3 Modelos ARIMA de Box-Jenkins

Desenvolvido por G. E. P. Box e G. M. Jenkins, o modelo analisa as propriedades probabilísticas (ou estocásticas) de séries temporais em si para “deixar que os dados falem por si mesmos”. Nos modelos de séries temporais de BJ, X_t pode ser explicado por valores passados (ou defasados) do próprio X e dos termos de erro estocásticos e suas defasagens. A estimação com esses modelos apresentam em relação aos modelos estruturais, a vantagem de não acumularem erros de variáveis explicativas, (GUJARATI, 2000).

O modelo básico geral aplicado a uma série com tendência é denominado ARIMA (*Autoregressive Integrated Moving Average*). A fórmula geral do modelo ARIMA, considerando a aplicação de d diferenças da série original X_t para que se torne estacionária é:

$$W_t = \Delta^d X_t = (1 - B)^d . X_t$$

$$W_t = \phi_1 . W_{t-1} + \phi_2 . W_{t-2} + \dots + \phi_p . W_{t-p} + a_t - \theta_1 . a_{t-1} - \theta_2 . a_{t-2} - \dots - \theta_q . a_{t-q}$$

Onde o operador auto-regressivo de ordem p é: $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$.

E o operador de médias móveis de ordem q é: $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$,

A expressão geral utilizando operadores de defasagem B e de diferenças Δ é:

$$\phi(B) . (1 - B)^d . X_t = \theta(B) . a_t, \quad \text{ou} \quad \phi(B) . \Delta^d . X_t = \theta(B) . a_t .$$

Os modelos ARIMA (p, d, q) podem ser ampliados para aplicação a séries sazonais na forma SARIMA $(p, d, q) . (P, D, Q)_s$ e cuja representação utilizando operadores de defasagem B e de diferenças é (MORETTIN, 2008):

$$\phi(B) . \Phi_s(B^s) . (1 - B)^d . (1 - B^s)^D X_t = \theta(B) . \Theta_s(B^s) . a_t, \quad \text{Onde:}$$

$\phi(B)$ é o operador auto-regressivo de ordem p ;

$\Phi_s(B^s)$ é o operador auto-regressivo sazonal de ordem P ;

$\theta(B)$ é o operador de médias móveis invertível de ordem q ;

$\Theta_s(B^s)$ é o operador de médias móveis sazonal de ordem Q , invertível;

$(1 - B)^d$ é o operador diferenças simples de ordem d ;


$(1 - B^s)^D$ é operador de diferença sazonal de ordem D .

Representação esquemática da metodologia Box-Jenkins. (MAKRIDAKIS *et. al.*, 1998).

Fase I : Identificação

Fase II: Estimação e Testes

Fase III: Aplicação



A inadequação de um modelo ou a má qualidade de uma previsão resulta em regra, da falta de apreciação da natureza estatística dos dados. Ao contrário dos modelos tradicionais de previsão, os modelos Box-Jenkins são baseados em conceitos e princípios estatísticos e são capazes de modelar o comportamento de grande variedade de séries temporais. O objetivo da metodologia é encontrar uma fórmula apropriada em que os resíduos são minimizados e apresentem um comportamento de ruído branco. O modelo mais adequado aos dados é escolhido mediante abordagem sistemática em que sua validade estatística é aferida por testes.

Três suposições básicas precisam ser observadas. A primeira diz respeito ao tamanho inicial da amostra, que deve ser de, no mínimo, 50 observações (BOX; JENKINS & REINSEL, 1994). A segunda suposição é a de que a série de dados

apresente média estacionária, isto é, que a série varie em torno de uma média. Os dados com tendência não-estacionária têm uma média que muda com o tempo. Se os dados forem homogêneos em primeira diferença, uma única diferenciação tornará a série estacionária. A terceira suposição para os modelos ARIMA é a de que a série seja homoscedástica, isto é, tenha uma variância constante ao longo do tempo. Se a amplitude da variação em torno da média aumentar com o tempo, mesmo após a diferenciação, a série é considerada heteroscedástica. A solução para este problema pode ser simples ou complexa e envolve outras medidas de ajustes.

O gráfico dos dados deve ser analisado inicialmente para identificar as características da série. Caso apresente tendências ou variância condicional, deve primeiramente ser ajustada mediante a aplicação de operadores lineares de diferenças ou logarítmicos para que a série se torne estacionária e/ou homoscedástica. A estabilidade ou estacionariedade da série é alcançada quando a série ajustada satisfaz as suposições mencionadas.

As séries analisadas, para a aplicação dos modelos Box-Jenkins, por serem baseados em processos estocásticos, devem possuir as seguintes características:

- (i) As observações devem possuir intervalos iguais de tempo e para garantir a precisão do ajustamento, conforme Box; Jenkins & Reinsel (1994), a série deverá possuir mais de 50 observações;
- (ii) Os dados deverão ser estacionários e, portanto, possuir as mesmas características estocásticas ao longo do tempo;

Segundo Box; Jenkins & Reinsel (1994), a construção dos modelos é baseada em um ciclo iterativo com base nos próprios dados e consiste de três etapas:

1. Etapa de Identificação:

Consiste em descobrir qual modelo ARIMA é o mais adequado para descrever o comportamento da série. Na prática, trata-se de identificar os valores apropriados para p , d e q . Pela análise do gráfico da série em estudo identificam-se a presença de tendência ou alteração na variância, característicos de um modelo não-estacionário. A análise do comportamento das funções de autocorrelação (ACF) e de autocorrelação parcial (FACP) indica qual o modelo mais adequado e auxilia no teste de raízes unitárias para verificação da estacionariedade. (teste de Dickey-Fuller).

2. Etapa de estimação:

Consiste em estimar os parâmetros ϕ do componente auto-regressivo, os parâmetros θ do componente de médias móveis e a variância de a_t e da constante do modelo, que representa o nível médio do processo. A estimativa dos parâmetros pode ser realizada pelos algoritmos disponíveis no software *EViews 5.1*.

3. Etapa de Verificação:

Consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados e então serem utilizados para fazer previsões. Caso contrário será necessário repetir as etapas de estimação e verificação.

Caso o modelo esteja corretamente especificado, os resíduos a_t deverão ser um ruído branco. O modelo estatisticamente adequado, segundo Pankratz (1983, p. 224), é aquele cujos erros são estatisticamente independentes, ou seja, não são autocorrelacionados, o que pode ser verificado pela sua função de autocorrelação. Os valores em módulo de t da estatística *t-Student* de todos os coeficientes devem satisfazer o nível de 5% de significância.

3.1.4 Análise de Intervenção

Entende-se por intervenção a ocorrência de algum tipo de evento em dado instante de tempo T , conhecido *a priori*, e que afeta temporariamente ou permanentemente a série em estudo, (MORETTIN; TOLOI, 2006). A análise de intervenção tem por foco avaliar o impacto de tal evento no comportamento da série e o principal objetivo é estimar o efeito dinâmico sobre o nível médio da série. A principal referência de análise de intervenção é Box e Tiao (1975). Ver também Box; Jenkins & Reinsel (1994, cap.12).

Uma maneira simples de estudo de análise de intervenção é a de considerar alguns modelos dinâmicos simples. Para este efeito, consideram-se dois tipos de séries de entrada: a função impulso e a função degrau. A função impulso indica que a intervenção só ocorre uma única vez em um instante T_0 enquanto que a função degrau mostra que a intervenção continua a existir a partir do instante T_0 .

Essas funções podem ser representadas por variáveis binárias:

a) A função degrau ("step function"), $S_t^{(T)} = \begin{cases} 0, \dots \text{para } t < T_0 \\ 1, \dots \text{para } t \geq T_0 \end{cases}$

b) A função impulso, $I_t^{(T)} = \begin{cases} 0, \dots \text{para } t \neq T_0 \\ 1, \dots \text{para } t = T_0 \end{cases}$

No caso da função degrau, o efeito da intervenção é permanente após o instante T, enquanto que na função impulso, o efeito é temporário. O uso de uma forma específica, ou de uma combinação das duas, é usualmente baseado na conveniência da interpretação do evento que afeta o modelo (WEI,1990).

Quando o instante e as causas das intervenções são conhecidos, é possível modelar esses choques para avaliar a sua significância para fins de previsão dos valores futuros da série.

A classe geral de modelos que leva em conta a ocorrência de múltiplas intervenções, segundo Morettin e Toloi (2006) é dada por:

$$Z_t = \sum_{j=1}^k v_j(B).X_{j,t} + N_t$$

Onde $X_{j,t}$ são variáveis de intervenção do tipo degrau ou impulso, $v_j(B)$ são funções de transferência racionais da forma $\frac{w(B).B^b}{\delta(B)}$, onde (b) mede o atraso do efeito. N_t é a série temporal livre do efeito das intervenções, denominada série residual. O modelo da série residual é um modelo SARIMA representado de forma geral por $\varphi(B).N_t = \theta(B).a_t$ utilizando a metodologia Box-Jenkins e modelado até o período anterior à ocorrência das intervenções.

Uma intervenção pode afetar uma série temporal de interesse de várias maneiras. Na sua manifestação ela pode ser abrupta ou gradual; na sua duração pode ser permanente ou temporária. Para cada efeito de intervenção tem-se uma forma apropriada para a função de transferência $v_j(B)$, (MORETTIN; TOLOI, 2006, p.302).

As variáveis I_t e S_t têm sido úteis para apresentar as seguintes características em uma série de dados:

i) Uma função impulso que representa uma intervenção somente na observação T, onde o efeito da intervenção é temporário;

ii) Uma função degrau em que o modelo apresenta um degrau na observação T, onde o efeito da intervenção é permanente após o instante T;

iii) É também possível definir combinações de ambas para modelar intervenções sucessivas.

O efeito impulso pode ser modelado nas seguintes formas básicas, (BOX; JENKINS; REINSEL, 1994):

- a) A intervenção I_t tem um efeito temporário sobre Z_t , com w_0 medindo o incremento inicial e δ a taxa de decrescimento.

$$v(B) = \frac{w_0}{1 - \delta \cdot B} \cdot I_t^{(T)}$$




Gráfico 9: Intervenção impulso 1

- b) Há um efeito passageiro w_0 e que causa um ganho (ou perda) permanente w_1 em Z_t ;

$$v(B) = \left\{ \frac{w_0}{1 - \delta \cdot B} + \frac{w_1}{1 - B} \right\} \cdot I_t^{(T)}$$




Gráfico 10: Intervenção impulso 2

- c) Há uma intervenção imediata w_0 seguida de um decaimento com efeito residual permanente, que pode ser representado pela seguinte equação:

$$v(B) = \left\{ w_0 + \frac{w_1}{1 - \delta \cdot B} + \frac{w_2}{1 - B} \right\} \cdot I_t^{(T)}$$




Gráfico 11: Intervenção impulso 3

O efeito degrau se apresenta nas seguintes formas básicas, (BOX; JENKINS; REINSEL, 1994):

a) Resposta imediata w_0 com efeito permanente.

$$v(B) = w_0 \cdot S_t^{(T)}$$




Gráfico 12: Intervenção degrau 1

b) Tem-se uma manifestação gradual da intervenção com duração permanente.

$$v(B) = \left\{ \frac{w_0}{1 - \delta \cdot B} \right\} S_t^{(T)}$$



Gráfico 13: Intervenção degrau 2

c) Representa o caso em que $\delta = 1$ produzindo uma rampa ou tendência em Z_t .

$$v(B) = \left\{ \frac{w_0}{1 - B} \right\} S_t^{(T)}$$




Gráfico 14: Intervenção degrau 3

Um procedimento geral para a análise de intervenção é o seguinte:

- Especificar um modelo para Z_t usando usando os dados até antes da intervenção no instante t_0 .
- Utilizar o modelo construído para obter as previsões Z'_t para $t \geq t_0$
- Examinar $Z_t - Z'_t$ para $t \geq t_0$ para especificar $\omega(B)$ e $\delta(B)$
- Executar a estimativa conjunta usando todos os dados para calcular o modelo.

$$Z_t = \frac{w(B)}{\delta(B)} \cdot X_t^T + \frac{\theta(B)}{\phi(B)} \cdot a_t$$

- Verificar a adequação do modelo mediante testes.

3.1.5 Modelos Causais ou Econométricos Dinâmicos

Os modelos econométricos causais de previsão apresentam um maior grau de complexidade, demandam uma maior quantidade de dados e uma análise estatística mais aprofundada, além de uma criteriosa escolha dos fatores causais baseados na teoria econômica do fenômeno a ser modelado. Essa abordagem é indicada para a previsão de receitas que são fortemente determinadas por fatores econômicos, como é o caso da arrecadação de tributos. As variáveis explicativas a serem incorporadas no modelo devem ter natureza exógena e serem relevantes na formação da receita e na política tributária.

Os modelos causais apresentam complexidade variada, desde os modelos mais simples univariados aos mais elaborados modelos de regressão múltipla. O processo de modelagem com dados de séries temporais torna-se mais difícil pela necessidade de modelar não só a interdependência entre as séries, mas também a dependência serial dentro de cada série, (CHATFIELD, 2000).

Um modelo econométrico tradicional de regressão múltipla com uma só equação poderia ser exemplificado na seguinte equação:

$$Y_t = c + \beta_1.X_{1t} + \beta_2.X_{2t} + \beta_3.X_{3t} + \beta_4.X_{4t} + + \beta_k.X_{kt} + u_t$$

Onde $u_t \sim NID [0, \sigma^2]$, distribuição normal e independente.

Uma representação geral de um modelo dinâmico considera as defasagens das variáveis explicativas até a ordem q . Algumas dessas defasagens poderão ser aceitas no modelo após análise da sua significância estatística:

$$Y_t = c + \varphi(B).X_1 + \varphi(B).X_2 + \varphi(B).X_3 + + \varphi(B).X_k + u_t, \text{ onde:}$$

$\varphi(B) = \theta_0 - \theta_1.B - \theta_2.B^2 - ... - \theta_q.B^q$, é a função defasagem de ordem q , aplicada a cada variável, e X_i representa as diversas variáveis explicativas incluídas no modelo.

Os modelos dinâmicos multivariados além se servirem para a obtenção de previsões, podem oferecer uma melhor compreensão da estrutura básica de um determinado sistema econômico. Embora esses modelos possam oferecer um melhor ajuste que os modelos univariados, o resultado das previsões nem sempre serão os melhores pelas seguintes razões, (CHATFIELD, 2000):

- i. Com mais parâmetros para estimar, aumenta a incerteza na estimação dos mesmos e que afetam as previsões.
- ii. Com mais variáveis para medir, há mais oportunidades para erros ou ocorrências de *outliers*.
- iii. Os dados observados podem não ser adequados para a aplicação do modelo multivariado.
- iv. O cálculo das previsões pode requerer valores futuros de variáveis explicativas que não estão disponíveis no instante em que a previsão é feita. A previsão de variáveis explicativas leva a uma redução da precisão do modelo.
- v. Os modelos multivariados, sendo mais complexos e difíceis de ajustar, são mais vulneráveis à má especificação do que os modelos univariados.

A literatura referente à modelagem multivariada destaca a importância de se obter informações suficientes de modo a compreender o contexto e identificar com precisão as variáveis relevantes para a formulação do modelo.

3.2 Teste ADF para Raízes Unitárias

A utilização do conceito de raiz unitária constatou que grande número de variáveis econômicas não apresenta equilíbrio estável no longo prazo, ou seja, as séries são não-estacionárias. O primeiro passo da análise de séries temporais consiste em avaliar se as séries são estacionárias ao longo do tempo. A não-estacionariedade de um processo estocástico é consequência da existência de raiz unitária no processo auto-regressivo gerador da variável.

Após as transformações das séries mediante a função logarítmica natural, inicia-se a investigação da estacionariedade das séries do modelo. Para verificar a existência ou não de raízes unitárias, utiliza-se neste trabalho o teste de Dickey-Fuller Aumentado (ADF). Este teste permite identificar a existência ou não de raiz unitária e a ordem da integração da variável em questão.

O teste geral de Dickey-Fuller (ADF) tem como hipótese nula a presença de raiz unitária no processo AR(p).

$$\Delta Y_t = a + \beta.T + \delta.Y_{t-1} + \theta_1.\Delta Y_{t-1} + \theta_2.\Delta Y_{t-2} + \dots + u_t$$

Consiste em testar a hipótese nula de que o coeficiente δ é igual a zero, ou seja, que existe uma raiz unitária. Se δ é igual a zero, diz-se que a série temporal tem uma raiz unitária e, portanto, segue um caminho aleatório não-estacionário. Caso contrário, a série é estacionária.

Este teste segue a distribuição τ , cujos valores críticos foram calculados por Mackinnon (1991). Quando o valor absoluto calculado da estatística τ for maior que os valores críticos absolutos de τ tabelado, rejeita-se a hipótese nula do teste. Por outro lado, se o valor de τ calculado for menor que o valor de τ tabelado em termos absolutos, aceita a hipótese de que a série temporal é não-estacionária. Estimando a equação pelo método MQO, o seguinte critério deve ser considerado:

A série é estacionária quando $\tau_{\text{calculado}} > \tau_{\text{crítico}}$ em valores absolutos.

3.3 Teste de Cointegração

A constatação da presença de raízes unitárias em muitas séries macroeconômicas estimulou o desenvolvimento da teoria da análise não-estacionária das séries temporais. Engle e Granger (1987) observaram que uma combinação linear de duas ou mais séries não-estacionárias podem ser estacionárias. Se tal combinação linear estacionária existe, as séries são ditas cointegradas e a combinação linear estacionária é chamada equação de cointegração e pode ser interpretada como uma relação de equilíbrio de longo prazo entre as variáveis.

Cointegração, portanto, é a propriedade estatística que garante a existência de uma relação de equilíbrio no longo prazo, não espúria, entre variáveis econômicas de séries temporais, mas com desvios de curto prazo provenientes de cada uma das séries.

O objetivo do teste de cointegração é determinar se um grupo de variáveis não-estacionárias são cointegradas ou não.

A definição de cointegração feita por Engle e Granger (1987) diz que, duas variáveis de séries temporais são cointegradas de ordem (k, m) , simbolicamente $CI(k, m)$, se:

- (i) São ambas integradas da mesma ordem k ,
- (ii) Existe uma combinação linear entre elas que seja integrada de ordem $k - m$.

O caso mais comum e usual de cointegração com variáveis econômicas é CI (1,1). Para testar a cointegração considera-se que há uma relação de longo prazo entre as variáveis Y_t e X_t do tipo:

$$Y_t = a + bX_t + u_t$$

Para verificar que esta relação não é espúria, precisamos demonstrar que as variáveis Y_t e X_t são cointegradas. Para isso, temos de:

- (i) Verificar através do teste ADF que as variáveis são estacionárias ou integradas da mesma ordem;
- (ii) Estimar pelo método MQO a equação de equilíbrio conhecida como regressão de cointegração e obter os resíduos;

$$\hat{u}_t = Y_t - \hat{a} - \hat{b}X_t \text{ para todos os } t,$$

- (iii) Testar a estacionariedade dos resíduos através do teste ADF;

$$\Delta \hat{u}_t = \delta^* \hat{u}_{t-1} + \theta_1 \Delta \hat{u}_{t-1} + \theta_2 \Delta \hat{u}_{t-2} + \dots + v_t$$

$$H_0 : \delta^* = 0 \text{ (resíduos não estacionários)}$$

$$H_A : \delta^* < 0 \text{ (resíduos estacionários)}$$

O critério de estacionariedade dos resíduos, o que implica cointegração entre as variáveis Y_t e X_t , é dado pela seguinte condição: $\tau_{estatístico} < \tau_{crítico}$, em valores absolutos. Além desse, existem outros testes para a verificação da cointegração. Ver Johansen (1988, 1991).

3.4 Mecanismo de Correção de Erros

Os desequilíbrios de curto prazo constatados entre duas séries cointegradas podem ser tratados como erros de equilíbrio, ou seja, como desvios de sua tendência de longo prazo. Dessa forma, esse termo de erro pode ser usado para ligar o comportamento da regressão estimada no curto prazo ao seu comportamento de longo prazo. A elaboração de um modelo de curto prazo com mecanismo de correção de erros poderá corrigir esse desequilíbrio, (ENGLE; GRANGER, 1991).

Sejam duas séries temporais Y_t e X_t , cointegradas de ordem I(1) e seja a dinâmica da relação entre elas dada pela seguinte equação, onde e_t é um termo ruído branco:

$$y_t = \beta_0 + \alpha.y_{t-1} + \beta_1 x_t + \beta_2 x_{t-1} + u_t$$

Usando o artifício matemático de subtrair y_{t-1} de ambos os lados da equação e adicionar e subtrair $\beta_1 x_{t-1}$ do lado direito da mesma; a equação poderá ser reparametrizada para a seguinte forma:

$$\Delta y_t = \beta_0 + \Delta \beta_1 x_t - (1 - \alpha) \cdot y_{t-1} - (\beta_1 - \beta_2) \cdot x_{t-1} + u_t$$

Fazendo $\theta = \frac{(\beta_1 - \beta_2)}{(1 - \alpha)}$, teremos o seguinte modelo de correção de erros que melhor representa a dinâmica das relações entre as variáveis das séries:

$$\Delta y_t = \beta_0 + \Delta \beta_1 x_t - (1 - \alpha) \cdot (y_{t-1} - \theta \cdot x_{t-1}) + e_t$$

Onde e_t é ruído branco e $(1 - \alpha)$ é a velocidade de ajustamento para o equilíbrio de longo prazo, sendo que $(1 - \alpha)$ deve ser menor que zero para garantir que o MCE obtenha o retorno à equação de longo prazo.

O modelo MCE mostra como y_t reage no curto prazo aos desvios em relação ao longo prazo. Mostra que a taxa de crescimento de y é explicada pela taxa de crescimento em x e pelo desequilíbrio passado entre essas variáveis.

Para uma equação multivariada teremos mais genericamente o seguinte modelo de correção de erros, onde Y representa um vetor de variáveis cointegradas $I(1)$ e X o vetor das variáveis explicativas do modelo:

$$\Delta Y_t = \alpha_0 + \beta(Y_{t-1} - \theta X_{t-1}) + \sum \alpha_{Yi} \Delta Y_{t-i} + \sum \alpha_{Xi} \Delta X_{t-i} + e_t$$

O procedimento para construção do mecanismo de correção de erros é apresentado nos seguintes passos (ENGLE; GRANGER, 1987) :

- I) Testar a ordem de integração das variáveis.
- II) Procurar a existência de cointegração entre as variáveis não-estacionárias $I(1)$ ou grupos dessas variáveis.
- III) Estimar a equação de longo prazo e verificar se os resíduos são estacionários.
- IV) Estimar a equação do MCE, onde a defasagem residual da equação de longo prazo é utilizada como termo de correção de erro. Determinar as defasagens usando os critérios AIC ou SIC e confirmar a estacionariedade dos resíduos.

3.5 A Crise Financeira Internacional

A crise financeira internacional de 2008 teve sua origem nas perdas causadas pela crise de pagamento das hipotecas de alto risco do mercado *subprime* americano e devido ao fato de que grande parte dessas hipotecas foram securitizadas e distribuídas aos investidores do mercado global, contaminando o sistema mundial. Os impactos mais destrutivos da crise foram sobre a produção e o emprego, o que provocou uma queda no PIB em quase todo o mundo e induziu forte retração no mercado de crédito e queda das bolsas de valores, (AKB, 2008).

A arrecadação tributária possui correlação direta com o nível de atividade econômica. Esse fenômeno fica evidente durante uma crise financeira global, que provoca recessão e eleva o desemprego. Nesse contexto, era de se esperar uma queda generalizada nas receitas tributárias. Tanto a análise descritiva quanto a econométrica corroboram a hipótese de que a queda verificada na arrecadação é explicada fundamentalmente pelas variáveis econômicas (IPEA, 2009a).

Segundo (IPEA, 2009b), a diferença entre a queda da produção real e a queda da arrecadação de tributos no Brasil pode ser explicada pela existência de diferentes elasticidades da arrecadação em relação à sua base e ao hiato¹ do produto, o que sinaliza que na fase descendente do ciclo econômico a arrecadação pode cair num ritmo mais intenso; o que de fato ocorreu com o ICMS.

As evidências apresentadas neste trabalho reforçam a hipótese de que houve uma quebra estrutural da arrecadação tributária do ICMS como efeito da súbita perda de dinamismo da economia a partir de dezembro de 2008. A queda observada na arrecadação está em sintonia com o comportamento das variáveis macroeconômicas com as quais o ICMS se relaciona e que formam a base de incidência tributária do imposto.

Para modelar o impacto efetivo da crise sobre a arrecadação do ICMS no Espírito Santo e utilizá-los para previsão, este trabalho compara os dados da Secretaria de Estado da Fazenda (SEFAZ-ES) referentes ao 1º semestre de 2009 com o período anterior quando a economia brasileira não sofria com a crise e apresenta uma função de transferência que ajusta o comportamento da série observada. Ver seção 4.5.

¹ Hiato do produto = produto potencial – produto real (DORNBUSH; FISCHER, 1991)

4. MODELOS DE SÉRIES TEMPORAIS E PREVISÕES

4.1 Alisamento Exponencial de Holt

São as equações do modelo conforme Makridakis *et al.* (1998):

$$L_t = \alpha.Y_t + (1-\alpha).(L_{t-1} + T_{t-1}).\dots\dots\dots(nível),\dots\dots\dots 0 < \alpha < 1$$

$$T_t = \beta.(L_t - L_{t-1}) + (1-\beta).T_{t-1}.\dots\dots\dots(tendência),\dots\dots\dots 0 < \beta < 1$$

$$F_{t+m} = L_t + m.T_t.\dots\dots\dots(previsão)$$

Este modelo, além da constante de alisamento α , do nível, apresenta um parâmetro β , que representa a tendência. Conforme Morettin e Toloi (2006), a previsão no tempo t para m períodos à frente é igual ao nível da série em t mais o produto de m pela tendência no tempo t . O nível resultante da série é estimado como uma função do valor da série no tempo t , do nível da série no tempo precedente e da tendência estimada no tempo precedente. O parâmetro β apresenta-se como um coeficiente de suavização aplicado à tendência. A tendência no tempo t é estimada como função suavizada da mudança de nível e da tendência no período anterior.




Gráfico 15: Modelo de Holt não sazonal.

O Gráfico 15 mostra a série original do ICMS e o modelo ajustado com as previsões para jan/2010 a ago/2010. A função para o período de *forecasting* apresenta-se como uma reta cujos parâmetros são ajustados pelos dados até a última observação do período amostral. Os dados da tabela 8 apresentam os valores dos parâmetros

calculados, com $\alpha=0,48$ e $\beta=0$, que levados às equações do modelo fornecem os valores das previsões.

O modelo foi ajustado utilizando software *EViews 5.1* para a escolha automática dos parâmetros pelo método dos mínimos quadrados dos erros. O cálculo de β com valor igual a zero indica que o melhor estimativa para a tendência atual é o seu valor no período precedente, conforme as equações acima.

Tabela 5: Previsão do ICMS pelo Modelo de Holt

MÊS	PREVISTO	ICMS	EA	EPA	EPAM
jan/10	587.673,30	584.483,00	3.190,30	0,55	0,55
fev/10	590.783,60	559.227,00	31.556,60	5,64	3,09
mar/10	593.894,00	566.365,00	27.529,00	4,86	3,68
abr/10	597.004,30	594.098,00	2.906,30	0,49	2,88
mai/10	600.114,60	574.263,00	25.851,60	4,50	3,21
jun/10	603.224,90	515.454,00	87.770,90	17,03	5,51
jul/10	606.335,20	494.118,00	112.217,20	22,71	7,97
ago/10	609.445,50	528.081,00	81.364,50	15,41	8,90
EPAM				8,90	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

A tabela 5 apresenta os valores previstos pelo modelo, com os respectivos erros absolutos e percentuais. A previsão para o período de jan/2009 a ago/2010 apresenta um erro percentual absoluto médio de 8,90 %.

4.2 Alisamento Exponencial de Holt-Winters Aditivo

Este modelo acrescenta ao de Holt uma componente sazonal, em adição à constante de alisamento e ao parâmetro de tendência. A forma aditiva deste modelo supõe que a sazonalidade seja constante ao longo do tempo e é dado pelas seguintes equações, conforme Makridakis *et al.*(1998):

$$\begin{aligned}
 L_t &= \alpha.(Y_t - S_{t-s}) + (1-\alpha).(L_{t-1} + T_{t-1}) \dots\dots\dots(nível), \dots\dots\dots 0 < \alpha < 1 \\
 T_t &= \beta.(L_t - L_{t-1}) + (1-\beta).T_{t-1} \dots\dots\dots(tendência), \dots\dots\dots 0 < \beta < 1 \\
 S_t &= \gamma.(Y_t - L_t) + (1-\gamma).S_{t-s} \dots\dots\dots(sazonalidade), \dots\dots\dots 0 < \gamma < 1 \\
 F_{t+m} &= L_t + m.T_t + S_{t-s+m} \dots\dots\dots(previsão)
 \end{aligned}$$




Gráfico 16: Modelo de Holt-Winters aditivo

O gráfico 16 apresenta a série original do ICMS e a série alisada com previsões a partir de jan/2010. Observa-se que as previsões já refletem o padrão sazonal presente nos períodos anteriores.

A tabela 8 apresenta os valores calculados para a constante de alisamento α e para os parâmetros de tendência β e de sazonalidade γ . Estes dois últimos são iguais a zero, indicando que a estimativa que minimiza os erros do modelo considera que a melhor previsão para os valores atuais da tendência e da sazonalidade são os seus valores respectivos no período precedente.

A tabela 6 apresenta os valores previstos pelo modelo, com os respectivos erros absolutos e percentuais. A previsão para o período de jan/2010 a ago/2010 apresenta um erro percentual absoluto médio de 6,44%.

Tabela 6: Previsão do Modelo Holt-Winters Aditivo

MÊS	PREVISÃO	ICMS	EA	EPA	EPAM
jan/10	594.348,60	584.483,00	9.865,60	1,69	1,69
fev/10	569.220,40	559.227,00	9.993,40	1,79	1,74
mar/10	560.998,80	566.365,00	-5.366,20	0,95	1,47
abr/10	579.576,10	594.098,00	-14.521,90	2,44	1,72
mai/10	563.359,60	574.263,00	-10.903,40	1,90	1,75
jun/10	584.064,20	515.454,00	68.610,20	13,31	3,68
jul/10	584.523,30	494.118,00	90.405,30	18,30	5,77
ago/10	587.079,10	528.081,00	58.998,10	11,17	6,44
EPAM				6,44	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

4.3 Alisamento Exponencial de Holt-Winters Multiplicativo

O modelo multiplicativo considera que a amplitude do ciclo sazonal varia em função do tempo, dependendo das características da série em estudo. As equações para o modelo apresentadas por Makridakis *et al.*(1998) são:

$$L_t = \alpha \cdot \frac{Y_t}{S_{t-s}} + (1-\alpha) \cdot (L_{t-1} + T_{t-1}) \dots \dots \dots (\text{nível}), \dots \dots \dots 0 < \alpha < 1$$

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1-\beta) \cdot T_{t-1} \dots \dots \dots (\text{tendência}), \dots \dots \dots 0 < \beta < 1$$

$$S_t = \gamma \cdot \frac{Y_t}{L_t} + (1-\gamma) \cdot S_{t-s} \dots \dots \dots (\text{sazonalidade}), \dots \dots \dots 0 < \gamma < 1$$

$$F_{t+m} = (L_t + T_t \cdot m) \cdot S_{t-s+m} \dots \dots \dots (\text{previsão})$$




Gráfico 17: Modelo de Holt-Winters multiplicativo

O gráfico 17 apresenta as séries original e ajustada com previsões para o período de jan/2010 a ago/2010. Observa-se a reprodução do padrão sazonal de forma mais acentuada que no modelo aditivo. Os cálculos dos parâmetros de tendência β e de sazonalidade γ apresentam valor zero na Tabela 8. Como constatado no modelo aditivo, para o cálculo das previsões este modelo não suaviza a tendência nem a sazonalidade e considera os valores do período anterior como a melhor estimativa para o período atual.

A tabela 7 apresenta os valores previstos pelo modelo, com os respectivos erros absolutos e percentuais. A previsão para o período de jan/2010 a ago/2010 apresenta um erro percentual absoluto médio de 6,65%.

Tabela 7: Previsão do Modelo Holt-Winters Multiplicativo

MÊS	PREVISÃO	ICMS	EA	EPA	EPAM
jan/10	615.389,00	584.483,00	30.906,00	5,29	5,29
fev/10	564.543,70	559.227,00	5.316,70	0,95	3,12
mar/10	568.697,10	566.365,00	2.332,10	0,41	2,22
abr/10	572.178,90	594.098,00	-21.919,10	3,69	2,58
mai/10	544.754,20	574.263,00	-29.508,80	5,14	3,10
jun/10	580.730,40	515.454,00	65.276,40	12,66	4,69
jul/10	572.418,40	494.118,00	78.300,40	15,85	6,28
ago/10	576.535,60	528.081,00	48.454,60	9,18	6,65
EPAM				6,65	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

Os métodos de alisamento representam tentativas de determinar uma espécie de “média” em torno da qual os valores estão fluando. Os métodos descritos acima são fáceis de descrever e simples de implementar. Os modelos estatísticos de Holt-Winters mostraram-se consistentes quanto à sua eficiência para fazer previsão, uma vez que foram observados excelentes níveis de ajuste entre os valores reais e os previstos para os primeiros cinco meses de previsão, com EPAM abaixo de 5%.

Na tabela 8 é apresentado o resumo com os valores dos parâmetros e dos respectivos erros calculados pelo software *EViews 5.1* para os três modelos. Os índices de sazonalidade calculados são apresentados no Apêndice A.

Tabela 8: Parâmetros para os Modelos de Holt-Winters da Série do ICMS

Modelo	Média	Tend	α	β	γ	SSR	RMSE
Holt não Sazonal	584563,00	3110,317	0.47	0.00	-	1.24E+11	32120,71
Holt-Winters Aditivo	566280,09	3600,253	0.42	0.00	0.00	9,26E+10	27774,03
Holt-Winters Multiplicativo	562837,80	3600,253	0.40	0.00	0.00	9.06E+10	27483,63

Fonte: Software *EViews 5.1*, SSR: soma do quadrado dos resíduos, RMSE: raiz do erro quadrático médio

4.4 Modelo de Box-Jenkins

A classe de modelos sazonais multiplicativos ARIMA $(p,d,q) \times (P,D,Q)_s$ ou SARIMA pode ser expressa pela seguinte expressão geral:

$$\phi(B) \cdot \Phi(B^s) \cdot (1-B)^d \cdot (1-B^s)^D Y_t = \theta_0 + \theta(B) \cdot \Theta(B^s) \cdot \varepsilon_t, \text{ onde } \varepsilon_t \approx RB(0, \sigma^2) \text{ (ruído branco)}$$

Observam-se neste modelo geral os componentes auto-regressivos, de médias móveis e de diferenciação simples e sazonal. A construção do modelo é baseada em um processo iterativo composto de três estágios: identificação, estimação e diagnóstico conforme Box; Jenkins & Reinsel, 1994, cap.6. Ver seção 3.1.3.

Identificação

O objetivo desta primeira fase da modelagem é determinar as ordens (p,d,q) e $(P,D,Q)_s$, pela observação do comportamento das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) e seus respectivos correlogramas. Segundo Morettin e Toloi (2006), o procedimento de identificação consiste de três partes: verificar a necessidade de transformação nos dados da série original com o objetivo de estabilizar a variância, diferenciar a série até se obter uma série estacionária e identificar o processo ARMA (p,q) adequado, através da análise das autocorrelações e autocorrelações parciais estimadas, cujos comportamentos devem “imitar” os comportamentos das respectivas quantidades teóricas.

As características teóricas das ACF e PACF para processos estacionários são mostradas na tabela 9 abaixo, conforme Wei (1994, p.106):

Tabela 9: Características Teóricas das ACF e PACF

Processo	ACF	PACF
AR (p)	Decaimento exponencial ou senoidal amortecido	Corta depois da defasagem p
MA (q)	Corta depois da defasagem q	Decaimento exponencial ou senoidal amortecido
ARMA (p,q)	Decaimento a partir de q	Decaimento a partir de p

Fonte: WEI (1994, p.106)

Na tabela 9 são apresentadas as características teóricas das FAC e FACP, que devem ser comparadas às da série estacionária estudada. O procedimento consiste na identificação das semelhanças entre as funções de autocorrelação teóricas e

amostrais que sejam boas sugestões para o processo escolhido e que melhor expliquem a dinâmica da série.

Pelas características da série do ICMS estudadas na seção 2.3 verificou-se que a série é não-estacionária em relação à média e que possui variância com estabilidade aceitável, conforme resultado da aplicação do modelo GARCH (1,1) na seção 2.3.4. Considerando a variabilidade observada nos extremos da série, no início de 2002 e no final de 2008 devido a fatores conjunturais e ao choque externo, tomaremos a transformação $\log(\text{ICMS})$ como base para o estudo do modelo. Será usado para a série amostral o período de jul/2001 a dez/2009 a fim de eliminar as flutuações da série no início de 2001.




Gráfico 18: FAC e FACP das séries $\log(\text{ICMS})$ e $d\log(\text{ICMS})$

Da análise do gráfico 18 observa-se que a FAC declina muito lentamente, sendo estatisticamente diferente de zero além da vigésima defasagem e que a FACP decai exponencialmente para zero após os picos na primeira e na segunda defasagem. As características das FACs deixam claro a não estacionariedade da série do ICMS, conforme já verificada mediante a aplicação do teste ADF para a identificação de raízes unitárias no item 2.3,2 e, portanto, a série original deverá estar em primeira diferença para que se torne estacionária e então seja aplicada a modelagem ARMA.

Após torná-la estacionária, a verificação da presença de sazonalidade pode ser investigada. O exame do gráfico das funções de autocorrelação para a série DICMS permite descartar a utilização do modelo ARIMA sazonal tendo em vista que apresentam correlações não significativas para as defasagens 12 e 24.

Pelos correlogramas da série após a primeira diferença, é possível identificar quais os possíveis padrões ARMA a serem testados na série. Para a identificação do valor do parâmetro auto-regressivo p , procedeu-se a análise do gráfico da FACP e observa-se a presença de picos nas defasagens 1 e 2 fora do intervalo de confiança e corte nas defasagens maiores que 2, o que sugere o valor de $p=1$ ou $p=2$. Para a identificação do valor do parâmetro de médias móveis q , observa-se que o gráfico da função FAC apresenta um lento amortecimento senoidal após pico na primeira defasagem. Pelo princípio da parcimônia, que recomenda a escolha de valores mínimos para p e q , serão investigados os modelos para $p=1$, $p=2$ e $q=1$.

Para modelos sazonais, o comportamento da FAC e FACP deve ser analisado próximo às defasagens múltiplas de 12, por se tratar de dados com periodicidade mensal. Constata-se pelo gráfico 18 que a primeira diferença normal da série já tornou a sazonalidade pouco significativa conforme havia sido previsto pela análise com variáveis *dummies*, sendo desnecessária a aplicação de diferenças sazonais.

Preliminarmente, a partir da combinação dos valores escolhidos para p e q , serão estimados modelos ARIMA para representar o mecanismo gerador da série no intervalo considerado.

A identificação é uma etapa crucial no processo de escolha do modelo adequado e requer um bom entendimento das características subjacentes à série mediante a análise da amostra, (WEI,1994). A complexidade do comportamento de uma série pode tornar a identificação uma tarefa subjetiva devido à variedade de modelos teóricos sugeridos. No entanto, para o ICMS, temos uma série relativamente bem comportada, com tendência de crescimento bem definida e ausência de ciclos ou sazonalidade significativos.

Para comparação dos modelos e aplicação do princípio da parcimônia, que aconselha a escolha do modelo com o menor número de parâmetros, será utilizado o critério de Akaike (AIC). O AIC incorpora em suas duas parcelas, medidas sobre o ajustamento e confiabilidade do modelo. A primeira parcela mede a imperfeição do ajuste (pela MV); a segunda mede o decréscimo de confiabilidade à medida que aumentamos o número de parâmetros estimados. O critério MAICE (menor valor do AIC) que seleciona o modelo, cuja estrutura com os valores dos parâmetros associados, dá o menor AIC, nos oferece uma formulação para o princípio da parcimônia na construção de modelos, (BRASIL, G.H., 2009, UFES).

O programa *EViews 5.1* forneceu os seguintes valores (tabela 10) para os critérios de seleção de Akaike (AIC) dos modelos, para o período amostral de jul/2001 a dez/2009.

Tabela 10: Avaliação dos Modelos ARIMA para dlog(ICMS)

Modelo	AIC	Modelo	AIC
(1) c ar(1)	-2,110658	(4) c ma(1)	-2,180599
(2) c ar(1) ar(2)	-2,224160	(5) c ar(1) ma(1)	-2,161482*
(3) c ar(1) ar(2) ma(1)	-2,204725*	(6) c ar(2) ma(1)	-2,164727*

Nota: Resultados do software *EViews 5.1*, * contém parâmetros não significativos

Logo, com base nessas informações, constata-se que o modelo que apresenta o menor valor para o critério AIC é o modelo (2), que será estimado na segunda fase da metodologia de Box-Jenkins.

Estimação

Nesta etapa da metodologia cada um dos modelos sugeridos na fase de identificação é ajustado para a obtenção dos vários coeficientes, que depois serão examinados para avaliação da sua significância estatística. Os modelos serão estimados pelo processo dos mínimos quadrados ordinários que, observados os pressupostos teóricos necessários, oferecem parâmetros consistentes e não viesados. A condição básica é que os resíduos do modelo tenham comportamento de ruído branco.

São pressupostos básicos a serem verificados no termo de erro e_t do modelo ARIMA estimado, WEI (1994, p.147):

- a) Média zero: $E(e_t) = 0$
- b) Ausência de autocorrelação: $E(e_t e_k) = 0$ para $t \neq k$
- c) Variância constante: $E(e_t^2) = \sigma_t^2$

As estimativas dos parâmetros e o correlograma para o modelo (2), escolhido por apresentar o menor valor para AIC, estão apresentados na tabela 11 abaixo:

Tabela 11: Parâmetros e Correlograma dos Resíduos do Modelo (2)

Dependent Variable: DLOG(ICMS) Method: Least Squares Date: 10/30/10 Time: 21:59 Sample: 2001M07 2009M12 Included observations: 102 Convergence achieved after 3 iterations White Heteroskedasticity-Consistent Standard Errors & Covariance					Date: 10/30/10 Time: 22:00 Sample: 2001M07 2009M12 Included observations: 102 Q-statistic probabilities adjusted for 2 ARMA term(s)					
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
C	0.010174	0.004173	2.438234	0.0165			1 -0.006 -0.006 0.0037			
AR(1)	-0.565560	0.094103	-6.010003	0.0000			2 -0.066 -0.066 0.4694			
AR(2)	-0.319992	0.103177	-3.101388	0.0025			3 -0.075 -0.076 1.0681 0.301			
							4 0.044 0.039 1.2763 0.528			
							5 -0.001 -0.011 1.2765 0.735			
R-squared	0.313031	Mean dependent var	0.008806				6 -0.004 -0.004 1.2782 0.865			
Adjusted R-squared	0.299153	S.D. dependent var	0.093689				7 -0.098 -0.094 2.3589 0.798			
S.E. of regression	0.078434	Akaike info criterion	-2.224160				8 -0.015 -0.021 2.3858 0.881			
Sum squared resid	0.609030	Schwarz criterion	-2.146955				9 -0.068 -0.083 2.9192 0.892			
Log likelihood	116.4322	F-statistic	22.55566				10 -0.045 -0.064 3.1502 0.925			
Durbin-Watson stat	1.983142	Prob(F-statistic)	0.000000				11 0.052 0.046 3.4684 0.943			
							12 0.141 0.127 5.8086 0.831			
Inverted AR Roots										
-.28+-.49i										

Os parâmetros obtidos na tabela acima são todos significativos para um grau de significância de 5%. A qualidade do ajustamento deve ser avaliada mediante a análise dos resíduos de cada equação que devem apresentar características de ruído branco. Caso contrário, o modelo pode apresentar erro de especificação e precisa ser revisto. Estes procedimentos são executados na terceira fase da metodologia Box-Jenkins; a fase de diagnóstico dos modelos.

Diagnóstico

Se os resíduos forem auto correlacionados, os coeficientes estimados não são capazes de explicar a dinâmica do processo que representam e o modelo deve ser rejeitado.

O modelo apresenta coeficientes estatisticamente significativos a 5% e as autocorrelações estimadas dos resíduos, apresentadas na tabela 11, atestam sua adequação pela ausência de padrões e por serem todas próximas de zero, indicando características de ruído branco. O teste LM de Breusch-Godfrey para correlação serial apresentou p-valor 0,57; o teste Arch LM para verificação de heteroscedasticidade resultou p-valor 0,65 e a estatística JB apresentou p-valor de 0,13 e, portanto, não podemos rejeitar a hipótese nula de normalidade dos resíduos.

O modelo tem a seguinte forma: $(1 - \phi_1 B^1 - \phi_2 . B^2) . (1 - B) . \log(ICMS_t) = \theta_0 + .a_t$

O gráfico 19 mostra o grau de ajustamento do modelo através do diagrama dos resíduos.




Gráfico 19: Diagrama dos resíduos ARIMA

Previsão

A equação geral para o modelo ARIMA c ar(1) ar(2) é mostrada abaixo, com o gráfico das previsões resultantes da modelagem, onde $Y_t = \log(ICMS)$.

$$(1 - \phi_1 B^1 - \phi_2 \cdot B^2) \cdot (1 - B) \cdot Y_t = \theta_0 + a_t, \quad Y_t = (1 + \phi_1) \cdot Y_{t-1} - (\phi_1 - \phi_2) \cdot Y_{t-2} - \phi_2 \cdot Y_{t-3} + \theta_0 + a_t$$

$$ICMS_t = EXP(Y_t)$$




Gráfico 20: Previsões do modelo ARIMA

O gráfico 20 apresenta as previsões obtidas para o período de jan/2010 a ago/2010 pelo método dinâmico do software *EViews 5.1* que utiliza os valores previstos dentro do intervalo de previsão para calcular os valores seguintes, como normalmente se daria numa prospecção *ex-ante*.

A tabela 12 apresenta os valores previstos pelo modelo, com os respectivos erros absolutos e percentuais. O resultado apresenta um erro percentual absoluto médio de 12,47%.

Tabela 12: Valores das previsões do modelo ARIMA c ar(1) ar(2)

MÊS	PREVISÃO	ICMS	ERRO ABS	EPA	EPAM
jan/10	587.709,40	584.483,00	3.226,40	0,55	0,55
fev/10	598.881,10	559.227,00	39.654,10	7,09	3,82
mar/10	615.224,30	566.365,00	48.859,30	8,63	5,42
abr/10	613.952,60	594.098,00	19.854,60	3,34	4,90
mai/10	621.201,80	574.263,00	46.938,80	8,17	5,56
jun/10	629.460,30	515.454,00	114.006,30	22,12	8,32
jul/10	629.460,30	515.454,00	114.006,30	28,41	11,19
ago/10	634.489,60	494.118,00	140.371,60	21,41	12,47
EPAM				12,47	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

Em muitos casos, as previsões obtidas com esse método são mais confiáveis do que as obtidas com a modelagem econométrica tradicional, especialmente para previsões de curto prazo, (GUJARATI, 2000). Neste caso observa-se que os erros médios de previsão são menores que 5% somente até dois períodos à frente. Depois atingindo a média de 12,47% para oito períodos. Esse resultado pode ser explicado pela provável mudança na estrutura da série do ICMS a partir do mês de dezembro de 2008 e por fatores conjunturais naturalmente não captados pelo histórico dos dados. Esse fato sugere a investigação de um modelo de intervenção a partir da constatação estatística de alterações na série, o que poderá ser avaliado pelo teste de previsão de Chow.

O teste de previsão de Chow (*Chow's forecast test*), CHOW (1960), é utilizado para testar a hipótese da estabilidade de uma equação ao longo de duas sub-amostras. Considerando que qualquer curva de crescimento pode ter pontos de alterações na sua estrutura, foi utilizado o teste de Chow para testar a hipótese de que há uma mudança na estrutura da arrecadação do ICMS a partir de dez/2008, motivada pelos efeitos da crise financeira mundial. O teste estima em primeiro lugar o modelo para uma sub-amostra até o ponto selecionado, a partir do qual são feitas previsões dos valores da variável dependente para o restante da amostra. Sob a hipótese nula que não há mudança estrutural na série a partir de dez/2008, o teste fornece estatísticas que permitem avaliar a estabilidade do modelo.

A tabela 13 apresenta o resultado do teste no qual as duas estatísticas F e LR indicam a rejeição da hipótese nula, concluindo então que há uma alteração na estrutura do modelo a partir de dez/2008 conforme registrado nos gráficos das demais variáveis utilizadas neste trabalho.

Tabela 13: Teste de Chow para o Modelo Box-Jenkins

Chow Forecast Test: Forecast from 2008M12 to 2009M12			
F-statistic	2.522228	Probability	0.005588
Log likelihood ratio	32.94613	Probability	0.001736

4.5 Modelo ARIMA com Análise de Intervenção

Quando o instante e as causas das intervenções são conhecidos, é possível modelar esses choques para avaliar a sua significância para fins de previsão dos valores futuros da série. A série em estudo apresenta dois períodos em que a variabilidade das observações é evidente no gráfico. O primeiro ocorre de jul/2000 a jun/2001 e o segundo de dez/2008 a mar/2009. Neste último observam-se dois valores extremos, em dez/2008 e em mar/2009, que poderão induzir um choque na variância da série, que poderá comprometer a acurácia das previsões.

O modelo ARIMA estimado no item anterior apresenta amplitudes significativas nos erros percentuais absolutos de previsão no intervalo de aferição da série, variando do mínimo de 0,55% em jan/2010 ao máximo de 28,41% em jul/2010.

Para aplicação da análise de intervenção na série do ICMS foram escolhidas as 89 observações do período de jul/2001 a nov/2008 para a modelagem da série residual, por não apresentarem flutuações significativas na variância e serem anteriores às intervenções objeto do estudo. Foi tomada a transformação logarítmica $\text{Log}(\text{ICMS})$ para suavizar os efeitos das flutuações da série. O gráfico 21 abaixo apresenta as funções FAC e FACP para a série $N_t = \text{log}(\text{ICMS})$ e $dN_t = d\text{log}(\text{ICMS})$ no intervalo escolhido.




Gráfico 21: FAC e FACP para N_t e dN_t

O modelo univariado pesquisado e ajustado pelo software *EViews 5.1* para representar a série residual, após a aplicação da metodologia adequada para identificação, estimação e diagnóstico, é o apresentado na tabela 14 a seguir e definido pela seguinte equação: $(1 - \phi_1 B - \phi_2 B^2) \cdot (1 - B) N_t = \theta_0 + (1 - \theta_3 B^3 - \theta_{14} B^{14}) a_t$ ou $(1 + 0,579 \cdot B + 0,483 \cdot B^2) \cdot (1 - B) \cdot N_t = \theta_0 + (1 + 0,351 \cdot B^3 - 0,618 \cdot B^{14}) \cdot a_t$.

Tabela 14: Parâmetros do Modelo Residual.

Dependent Variable: DLOG(ICMS)				
Method: Least Squares				
Date: 11/09/10 Time: 21:49				
Sample: 2001M07 2008M09				
Included observations: 87				
Convergence achieved after 14 iterations				
White Heteroskedasticity-Consistent Standard Errors & Covariance				
Backcast: 2000M05 2001M06				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.011908	0.004138	2.877962	0.0051
AR(1)	-0.578971	0.075313	-7.687521	0.0000
AR(2)	-0.483241	0.081120	-5.957127	0.0000
MA(3)	-0.351562	0.074505	-4.718650	0.0000
MA(14)	0.618375	0.067825	9.117147	0.0000
R-squared	0.525658	Mean dependent var		0.010335
Adjusted R-squared	0.502519	S.D. dependent var		0.091735
S.E. of regression	0.064703	Akaike info criterion		-2.582279
Sum squared resid	0.343286	Schwarz criterion		-2.440560
Log likelihood	117.3291	F-statistic		22.71775
Durbin-Watson stat	1.963584	Prob(F-statistic)		0.000000
Inverted AR Roots	-.29+.63i	-.29-.63i		
Inverted MA Roots	.97-.20i	.97+.20i	.76+.58i	.76-.58i
	.40-.85i	.40+.85i	-.03-.96i	-.03+.96i
	-.44-.89i	-.44+.89i	-.75-.63i	-.75+.63i
	-.92+.22i	-.92-.22i		

Da análise do gráfico original da série do ICMS (gráfico 3) nota-se que a partir do mês de dezembro de 2008 há uma queda acentuada na arrecadação até março de

2009 quando então há uma inversão na tendência, na forma de uma função degrau negativa, devido ao aparente deslocamento da reta de tendência (gráfico 22). Para identificar as características e a significância dessa intervenção, será introduzida no modelo residual obtido acima, uma função de transferência em forma de degrau para captar a perturbação observada na série original. Pela observação do gráfico do ICMS infere-se que a função deverá ter a seguinte forma: $v(B) = w_0$.




Gráfico 22: Arrecadação ICMS Jul/2007 a Dez/2008 e função intervenção.

O modelo de intervenção foi construído por inferência a partir das características do gráfico da série amostral do ICMS no período de jul/2007 a dez/2009 (gráfico 22). Período em que ficam evidentes os efeitos da crise financeira internacional na arrecadação.

Seja $X_{j,t} = \begin{cases} 0, \dots \text{para } t < T \\ 1, \dots \text{para } t \geq T \end{cases}$, uma função do tipo degrau, com $T = \text{dez}/2008$.

E $\log(\text{ICMS}) = Z_t = \sum_{j=1}^k v_j(B) \cdot X_{j,t} + N_t$ a série transformada original a ser modelada

após a análise das intervenções e $N_t = \frac{\theta_0 + (1 - \theta_3 \cdot B^3 - \theta_{14} \cdot B^{14}) \cdot a_t}{(1 - B) \cdot (1 - \phi_1 B - \phi_2 B^2)}$ a série residual

escolhida para o intervalo de jul/2001 a nov/2008. Temos então o seguinte modelo geral a ser estimado para o período de jul/2001 a dez/2009 com as intervenções consideradas:

$Z_t = v(B) \cdot X_t^T + N_t$, onde T indica o momento do início da intervenção em dez/2008.

Substituindo $v(B)$ e N_t pelos seus respectivos valores temos:

$$Z_t = w_0 \cdot X_t + \frac{\theta_0 + (1 - \theta_3 \cdot B^3 - \theta_{14} \cdot B^{14}) \cdot a_t}{(1 - B) \cdot (1 - \phi_1 B - \phi_2 B^2)}$$

Fazendo $Z_t = \log(ICMS)$ e $X_t = deg$ a função tipo degrau com valores iguais a 1 a partir do mês de dezembro de 2008, instante em que a arrecadação do ICMS atingiu o seu valor máximo e começou a declinar.

O modelo estimado (tabela 15) apresenta quase todos os parâmetros significativos ao nível de 5%, indicando bom grau de ajustamento e que a série poderá ser modelada mediante a introdução de uma função de transferência tipo degrau no mês de dezembro/2008, com reflexo em todos os valores seguintes.

Tabela 15: Parâmetros e Correlograma dos Resíduos para o Modelo com Intervenção

Dependent Variable: DLOG(ICMS) Method: Least Squares Date: 02/14/11 Time: 21:15 Sample: 2001M07 2009M12 Included observations: 102 Convergence achieved after 11 iterations White Heteroskedasticity-Consistent Standard Errors & Covariance Backcast: 2000M05 2001M06					Date: 02/14/11 Time: 21:18 Sample: 2001M07 2009M12 Included observations: 102 Q-statistic probabilities adjusted for 4 ARMA term(s)						
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
C	0.013178	0.003916	3.364950	0.0011			1	0.035	0.035	0.1257	
DEG	-0.019252	0.006212	-2.344430	0.0211			2	0.019	0.017	0.1620	
AR(1)	-0.598940	0.079955	-7.490974	0.0000			3	-0.007	-0.009	0.1678	
AR(2)	-0.479977	0.093800	-5.117030	0.0000			4	0.052	0.052	0.4583	
MA(3)	-0.405595	0.062384	-6.501602	0.0000			5	-0.053	-0.056	0.7621	0.383
MA(14)	0.583488	0.059488	9.808531	0.0000			6	-0.103	-0.102	1.9327	0.380
R-squared	0.446317	Mean dependent var	0.008806				7	-0.040	-0.030	2.1080	0.550
Adjusted R-squared	0.417479	S.D. dependent var	0.093689				8	0.062	0.066	2.5486	0.636
S.E. of regression	0.071507	Akaike info criterion	-2.361034				9	-0.085	-0.085	3.3714	0.643
Sum squared resid	0.490666	Schwarz criterion	-2.226524				10	-0.124	-0.117	5.1493	0.525
Log likelihood	127.4327	F-statistic	15.47689				11	0.116	0.127	6.7208	0.459
Durbin-Watson stat	1.886546	Prob(F-statistic)	0.000000				12	0.186	0.172	10.779	0.215
Inverted AR Roots	-.30-.62i	-.30+.62i									
Inverted MA Roots	.97-.20i	.97+.20i	.76-.57i	.76+.57i							
	.40-.85i	.40+.85i	-.03+.96i	-.03-.96i							
	-.44+.89i	-.44-.89i	-.74+.63i	-.74-.63i							
	-.91+.22i	-.91-.22i									

As autocorrelações estimadas dos resíduos, apresentadas na tabela 15, atestam sua adequação, pela ausência de padrões e por serem todas próximas de zero, indicando características de ruído branco. O teste LM de Breusch-Godfrey para correlação serial apresentou p-valor 0,95 para seis defasagens; o teste Arch LM para verificação de heteroscedasticidade resultou p-valor 0,80 para seis defasagens e a estatística JB apresentou p-valor de 0,12, portanto, não podemos rejeitar a hipótese nula de normalidade dos resíduos.

Outras alternativas básicas de intervenção baseadas nas funções impulso e na função degrau foram testadas para cada mês do intervalo de nov/2008 a abr/2009 e todas apresentaram menor significância estatística que a intervenção escolhida.

Previsões

A tabela 16 abaixo apresenta as previsões com o modelo ajustado e os respectivos erros para o período de jan/2010 a ago/2010.

Tabela 16: Previsão com intervenção tipo degrau em dez/2008.

MÊS	PREVISÃO	ICMS	ERRO ABS	EPA	EPAM
jan/10	604.160,90	584.483,00	19.677,90	3,37	3,37
fev/10	611.158,10	559.227,00	51.931,10	9,29	6,33
mar/10	550.299,20	566.365,00	16.065,80	2,84	5,16
abr/10	556.060,10	594.098,00	38.037,90	6,40	5,47
mai/10	498.298,30	574.263,00	75.964,70	13,23	7,02
jun/10	546.150,00	515.454,00	30.696,00	5,96	6,85
jul/10	531.922,50	494.118,00	37.804,50	7,65	6,96
ago/10	499.183,70	528.081,00	28.897,30	5,47	6,77
EPAM				6,77	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

O gráfico 23 compara os resultados previstos e realizados para a arrecadação do ICMS no período de jan/2010 a ago/2010. Verifica-se que a introdução da função de transferência no modelo ARIMA obteve uma redução de 46% do erro de previsão EPAM para o intervalo.




Gráfico 23: Previsões do modelo ARIMA com intervenção

O coeficiente de desigualdade de Theil, que é insensível a mudanças de escala e seus valores variam entre zero e um, mede a aderência das previsões aos dados, onde zero indica um ajuste perfeito. Nota-se que o seu valor confirma as melhores previsões obtidas com o último modelo.

5. MODELO ECONOMÉTRICO DINÂMICO

Em modelos de séries temporais econômicas a dependência de uma variável Y em relação a uma ou mais variáveis explicativas X, raramente ocorre de forma instantânea. Pode-se afirmar que a natureza econômica do relacionamento entre as variáveis produz ajustamentos distribuídos ao longo do tempo. Nesse caso, variáveis explicativas defasadas devem ser explicitamente incluídas no modelo. Se o modelo de regressão incluir não somente os valores correntes, mas também os valores defasados das variáveis explicativas será denominado modelo de defasagem distribuída. Se incluir um ou mais valores defasados da variável dependente entre as suas variáveis explicativas, é chamado de modelo auto-regressivo. Este modelo é conhecido também como modelo dinâmico, pois retrata o caminho natural da variável dependente em relação aos seus valores passados, (GUJARATI, 2000).

Modelos econométricos dinâmicos de series temporais usualmente apresentam como regressores tanto variáveis explicativas defasadas quanto a variável dependente defasada.

$$Y_t = \alpha_0 + \alpha_1.Y_{t-1} + + Y_{t-p} + \beta_0 X_t + \beta_1.X_{t-1} + \beta_k.X_{t-k} + u_t$$

O modelo acima é chamado de auto-regressivo com defasagens distribuídas ADL(1,1) e pode ser generalizado mediante a inclusão de outras variáveis explicativas do lado direito da equação.

Utilizando-se a notação de operador de defasagem teremos a seguinte equação para o modelo generalizado:

$$A(L)Y_t = m + B_1(L).X_{1t} + B_2(L).X_{2t} + + B_k(L).X_{kt} + u_t, \quad \text{com}$$

$$A(L) = 1 - \alpha_1 L - \alpha_2 L^2 - - \alpha_p L^p \quad \text{e} \quad B(L) = 1 + \beta_1 L + \beta_2 L^2 - - \beta_p L^p,$$

e onde a ordem dos operadores polinomiais de defasagem são $p, q_1, q_2, ..., q_k$, para cada variável explicativa, respectivamente.

A questão crucial na construção do modelo econométrico dinâmico com defasagens distribuídas é definir quais as variáveis que devem aparecer como regressores e quais devem ser as ordens de suas defasagens, (JOHNSTON; DINARDO, 1997).

A definição de um modelo econométrico geral pressupõe inicialmente a inclusão de variáveis irrelevantes, mas depois de submetido a um processo de reduções sucessivas mediante vários testes, apresentará coeficientes não viesados, distúrbios da variância propriamente estimados e procedimentos de inferência válidos, (JOHNSTON; DINARDO, 1997).

Partindo-se da definição de um modelo geral conforme a metodologia tradicional, com defasagens distribuídas, será utilizada a metodologia que ficou conhecida como geral-para-específico ou Abordagem de Hendry, que introduziu a prática da construção de modelos partindo da especificação de um modelo econométrico geral auto-regressivo com defasagens distribuídas para, mediante reduções sucessivas e análise de cointegração das séries temporais envolvidas, obter um modelo mais simples e consistente para fins de previsão econométrica.

Erros de Especificação

Segundo Gujarati (2000), após especificar um modelo como sendo o correto, é possível que cometamos um ou mais dos erros de especificação a seguir:

a) Omissão de uma variável relevante.

Com a omissão de uma variável relevante, os coeficientes das variáveis mantidas no modelo são em geral viesados e inconsistentes, a variância do erro será estimada incorretamente e os procedimentos usuais para testar hipóteses se tornarão inválidos.

b) Inclusão de uma variável desnecessária.

Incluir no modelo uma variável irrelevante produz estimativas não-viesadas e consistentes dos coeficientes no modelo verdadeiro, a variância do erro é corretamente estimada e os métodos convencionais para testar hipóteses ainda são válidos. Como consequências negativas terão variâncias estimadas dos coeficientes maiores e as inferências sobre os parâmetros serão menos precisas.

c) Adoção da forma funcional errada.

A especificação incorreta do modelo apresenta as seguintes consequências: multicolinearidade, quando as variáveis irrelevantes estão correlacionadas com as relevantes; viés e inconsistência, se as variáveis omitidas estão correlacionadas com as variáveis incluídas.

5.1 Abordagem do Modelo Geral para o Específico

A abordagem ou metodologia de Hendry, conhecida como abordagem do geral para o específico, sugere a definição de um modelo mais geral, com diversos regressores e suas respectivas defasagens, e em seguida a redução gradual deste mesmo modelo até a obtenção de um modelo consistente estatisticamente. Essa abordagem foi empregada por Corvalão (2002) com bons resultados para a previsão do ICMS do estado de Santa Catarina.

A redução é processada mediante a eliminação dos regressores estatisticamente insignificantes e embasada nos resultados dos testes que mensuram as significâncias das variáveis no modelo, até o momento em que se acredite ter encontrado a forma específica.

Gilbert (1986) apresenta uma excelente discussão sobre a metodologia do geral para o específico, na qual simplifica a equação geral do processo gerador de dados mediante quatro etapas:

- (I) Marginalização: consiste na seleção das variáveis explicativas de interesse, dentre todas aquelas com dados de séries temporais disponíveis e que atendem os indicativos da teoria econômica relativa ao fenômeno em estudo;
- (II) Condicionamento: consiste na análise das variáveis selecionadas para a determinação daquelas que serão consideradas endógenas (condicionadas) ou exógenas. Para que o condicionamento seja válido para fins de estimação e testes, as variáveis independentes devem ser pelo menos fracamente exógenas;
- (III) Reparametrização: consiste na seleção de uma forma funcional específica, que deverá ser o mais adequado e simples. É o procedimento de ajuste do modelo geral para o modelo específico, mediante reduções até que se chegue ao modelo mais parcimonioso;
- (IV) Estimação: parâmetros desconhecidos devem ser substituídos por valores estimados.

As vantagens da metodologia de Hendry são as seguintes:

- a) Os erros de uma especificação incorreta são reduzidos;
- b) Permite uma escolha segura entre modelos alternativos compatíveis com a teoria;
- c) Define a estrutura dinâmica dos modelos e distingue os efeitos de curto e longo prazo;

d) Evita correlações falsas que podem surgir quando as variáveis não são estacionárias. Neste caso as inferências estatísticas MQO não são confiáveis. As variáveis expressas em primeiras diferenças, que fazem parte do MCE são na maioria dos casos estacionárias;

5.2 Seleção das Variáveis

A seleção das possíveis variáveis explicativas capazes de afetar a variável dependente do modelo é o primeiro passo para a elaboração da equação inicial. Deve ser considerada a teoria econômica relativa ao contexto da variável em estudo e realizada uma análise empírica do comportamento das séries temporais correlacionadas direta ou indiretamente com a variável endógena.

A importância econômica de uma variável é insuficiente para justificar a sua inclusão no modelo de previsão. Armstrong (1985, p.196) enumera quatro condições necessárias para a inclusão de uma variável em um modelo:

- (I) Uma forte relação causal esperada, ou seja, a variável deve ter um significado econômico);
- (II) A relação de causalidade pode ser estimada com precisão;
- (III) A variável causal sofre mudanças substanciais ao longo do tempo e
- (IV) As mudanças na variável causal podem ser previstas com precisão.

Se, após análise, for constatado que uma variável não satisfaz uma ou mais dessas condições, então é improvável que a mesma seja útil na previsão, (ALLAN; FILDES, 2001)

No caso da arrecadação tributária do ICMS, a legislação reguladora do imposto, sua base tributária de incidência e a teoria econômica fornecem informações sobre quais setores da economia que são os mais afetados pela carga tributária. Outros fatores econômicos exógenos capazes de alterar a dinâmica da produção ou do consumo também podem ter reflexos indiretos no volume arrecadado.

Conforme a disponibilidade e acesso aos dados existentes e descritos no capítulo 2, foram selecionadas as séries de variáveis explicativas numéricas VIMP, IPIND, IVVAR, IVABF, VPET, VGAS, VDIE e INEF, as quais foram transformadas mediante a aplicação da função logarítmica natural para a estabilização das séries.

Considerando que apenas duas variáveis são dadas em valores monetários e que apenas a variável dependente poderia ser afetada pelo deflacionamento dos valores, optou-se pela utilização dos valores nominais brutos da série do ICMS. Dessa forma, os valores previstos serão nominais, cuja acurácia poderá ser comparada em trabalhos futuros utilizando valores deflacionados. O gráfico 24 apresenta as séries em nível após transformadas por logaritmo natural.




Gráfico 24: Séries transformadas por logaritmo natural.

5.3 Análise da Estacionariedade e da Ordem de Integração.

Uma série temporal é estacionária se a sua média e sua variância não se alteram sistematicamente ao longo do tempo e o valor da covariância entre dois períodos depende apenas da distância (lag) entre os dois períodos e não do período atual no qual a covariância tem sido calculada. As séries temporais em níveis, na maioria dos casos, apresentam uma tendência crescente ou decrescente e por isso são não estacionárias. Uma forma de remover a tendência e assim obter séries estacionárias é expressar as séries em primeiras diferenças ou em taxas de crescimento.

As séries históricas consideradas como variáveis endógenas (dependentes no modelo a ser estimado) ou exógenas (independentes) precisam ser estacionárias para que possam ser bem representadas por um modelo linear dinâmico, devido ao seu caráter probabilístico. Se forem não estacionárias, devem pelo menos ser

integradas de mesma ordem para a avaliação da presença de cointegração entre elas para a formação de um modelo consistente de longo prazo com as séries em nível.

Com o objetivo de estabilizar as variâncias das séries, o primeiro passo foi aplicar a transformação logarítmica, a fim reduzir a heteroscedasticidade usualmente presente nas séries econômicas.

5.3.1 Aplicação do Teste das Raízes Unitárias

Será estimado o modelo mais geral, com tendência e intercepto, para cada série. Se os dados forem não-estacionários, isto é, o valor absoluto calculado da estatística t for menor do que o valor absoluto crítico de t para 5% de significância, então será preciso verificar se o coeficiente da tendência (@trend) é significativo ou não. Se a tendência @trend for significativa, podemos concluir que os dados possuem tendência determinística. Se a tendência não é significativa, então deverá ser estimado o modelo com intercepto.

Se o modelo com intercepto for não-estacionário, verifica-se a significância do termo constante para ter certeza de sua aceitação na regressão. Caso contrário, usa-se o modelo sem constante e intercepto (none).

Aplicando o teste ADF às séries no período amostral de 2000:01 a 2009:12 observando a metodologia descrita acima, teremos os seguintes resultados da tabela 17:

Tabela 17: Teste ADF da Raiz Unitária para Todas as Séries

Variável	C	@trend	t-ADF nível	p (nível)	t-ADF Δ	p (Δ)	Integ
LICMS	x	x	-2,703016	0,2375	-13,70041	0,0000	I(1)
LVIMP	x	x	-2,032127	0,5775	-19,86276	0,0000	I(1)
LIPIND	x	x	-2,997392	0,1374	-15,00142	0,0000	I(1)
LVVAR	x	x	-2,305563	0,4270	-2,787122	0,0635	I(1)
LVPET	x	x	-2,641254	0,2632	-13,22696	0,0000	I(1)
LIVABF	x	x	-2,231370	0,4672	-3,029448	0,0353	I(1)
LVGAS	x	x	-6,181219	0,0000	-	-	I(0)
LVDIE	x	x	-4,431757	0,0029	-	-	I(0)
LINEF	x	x	-3,340213	0,0649	-8,212268	0,0000	I(1)

Nota: Defasagens pelo critério SIC calculadas automaticamente pelo EViews 5.1

Conforme podemos ver na tabela 17, o teste ADF indica a presença de raiz unitária em seis das oito séries explicativas, ao nível de significância de 5%, das quais cinco se tornam estacionárias após a primeira diferenciação. No entanto, para a série LVVAR, o teste ADF indica a presença de raiz unitária mesmo depois de aplicado o operador de diferenças. Considerando que, se houver mudança estrutural na série, o teste ADF pode apresentar viés na direção da não rejeição da hipótese nula, mesmo se a série for estacionária; executou-se o teste de Phillips-Perron para raízes unitárias sobre a primeira diferença da série LVVAR, resultando $t = -28,05$ e $p = 0,0001$. Portanto, podemos afirmar que para valores críticos de 5% de significância as séries LICMS, LVIMP, LPIND, LVVAR, LVPET, LVABF e LINEF, são integradas $I(1)$. Os gráficos das séries em primeiras diferenças são apresentados abaixo:




Gráfico 25: Séries explicativas em primeiras diferenças

5.4 Marginalização e Condicionamento

Para a escolha das variáveis que irão participar do modelo, inicialmente estimaremos a equação de longo prazo contendo todas as séries $I(1)$, excluindo as séries LVGAS e LVDIE por não apresentarem o mesmo grau de integração das demais. A equação estimada permitirá a verificação da significância dos parâmetros e da magnitude dos coeficientes (tabela 18).

Tabela 18: Estimação Inicial da Equação de Longo Prazo

Dependent Variable: LICMS				
Method: Least Squares				
Date: 11/04/10 Time: 15:49				
Sample: 2000M01 2009M12				
Included observations: 120				
White Heteroskedasticity-Consistent Standard Errors & Covariance				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6.086226	0.948540	6.416416	0.0000
LVIMP	0.141826	0.045120	3.143326	0.0021
LPIND	-0.071778	0.086556	-0.829265	0.4087
LVVAR	-0.182993	0.176282	-1.038074	0.3015
LVPET	-0.431605	0.091112	-4.737061	0.0000
LIVABF	0.607683	0.221970	2.737678	0.0072
LINEF	1.740706	0.193894	8.977615	0.0000
R-squared	0.954743	Mean dependent var	12.69022	
Adjusted R-squared	0.952340	S.D. dependent var	0.447295	
S.E. of regression	0.097649	Akaike info criterion	-1.758307	
Sum squared resid	1.077497	Schwarz criterion	-1.595704	
Log likelihood	112.4984	F-statistic	397.3128	
Durbin-Watson stat	1.559674	Prob(F-statistic)	0.000000	

A estimativa *a priori* do modelo geral de longo prazo revela a inconsistência dos sinais dos coeficientes das séries LPIND, LVVAR e LVPET, tendo em vista que era de se esperar que todas contribuíssem positivamente para a composição da arrecadação do ICMS conforme inferimos da teoria econômica e da incidência tributária do imposto. Verifica-se também a não significância dos coeficientes de LPIND e LVVAR.

5.4.1 Teste de Causalidade de Granger

Para se testar esse relacionamento será utilizado o teste de causalidade proposto por Granger (1969). No conceito de Granger, se a variável X causa Y, isso significa que os valores defasados da variável X ajudam a prever Y, ou seja, se melhores previsões estatisticamente significantes de Y podem ser obtidas ao incluirmos valores defasados de X aos valores defasados de Y.

Para avaliar o grau de exogeneidade das variáveis explicativas do modelo será aplicado o teste de causalidade, no sentido de Granger, para assegurar que as variáveis sejam ao menos fracamente exógenas, condição necessária para que o modelo seja aplicado em previsões.

Tabela 19: Teste de Causalidade de Granger

Pairwise Granger Causality Tests			
Date: 11/04/10 Time: 16:02			
Sample: 2000M01 2009M12			
Lags: 6			
Null Hypothesis:	Obs	F-Statistic	Probability
LVIMP does not Granger Cause LICMS	114	4.07822	0.00105
LICMS does not Granger Cause LVIMP		1.90341	0.08743
LPIND does not Granger Cause LICMS	114	3.89448	0.00154
LICMS does not Granger Cause LPIND		2.82456	0.01391
LVVAR does not Granger Cause LICMS	114	1.31709	0.25642
LICMS does not Granger Cause LVVAR		1.42587	0.21206
LIVABF does not Granger Cause LICMS	114	0.79557	0.57554
LICMS does not Granger Cause LIVABF		1.16000	0.33377
LVPET does not Granger Cause LICMS	114	0.67266	0.67194
LICMS does not Granger Cause LVPET		2.25781	0.04368
LINEF does not Granger Cause LICMS	114	2.37233	0.03476
LICMS does not Granger Cause LINEF		1.69959	0.12873

O teste de causalidade de Granger indica a aceitação da hipótese de não-causalidade para as variáveis LVVAR, LIVABF e LVPET, em relação à LICMS, para um nível de significância estatística de 10%. Ver tabela 19. Não obstante essa constatação, na ausência de outros fatores restritivos, essas variáveis poderiam ser incluídas no modelo geral, tendo em vista que a relação de causalidade pode ser interpretada como precedência temporal, conforme sugere Leamer (1985). Além disso, nossas convicções sobre causalidade devem ser extraídas de fora da estatística, baseando-se na teoria econômica já estabelecida para a questão em estudo. Portanto, com base no resultado da estimação da equação geral contendo todas as variáveis e no resultado do teste de Granger, poderemos reduzir a equação do equilíbrio geral de longo prazo mediante a exclusão das séries LPIND, LVVAR e LVPET, por apresentarem inconsistência ou não-significância dos coeficientes ou pela não-causalidade no sentido de Granger. Restando apenas as séries LVIMP, LIVABF e LINEF como aptas para integrar a equação de equilíbrio de longo prazo.

Uma relação estatística, mesmo sendo significativa, não pode *a priori* estabelecer uma relação causal entre as variáveis. A idéia de causa e efeito deve vir de fora da estatística e ser amparada pela teoria econômica subjacente ao fenômeno em estudo.

Considerando o resultado da análise do teste de raízes unitárias, que identificou as séries LVIMP, LVABF e LINEF como integradas de ordem I(1) e, portanto, com o

mesmo grau de integração da série LICMS. Será aplicado o procedimento de dois estágios de Engle e Granger para verificar a existência de relação de cointegração entre elas.

5.4.2 Teste de Cointegração

A tabela 20 mostra o resultado do teste de Engle-Granger para a verificação da existência de relação de cointegração entre as séries LVIMP, LIVABF e LINEF, e a série LICMS.

Tabela 20: Teste de Cointegração de Engle-Granger

Série	t – ADF resid	p – ADF resid	d – DW - resid	Cointegrada
LVIMP	-2,253843	0,0239	0,800229	sim
LIVABF	-2,521141	0,0120	1,389073	sim
LINEF	-3,566808	0,0005	1,150922	sim

Obs.: Valores críticos EG: 1% = -2,5899, 5% = -1,9439. DW: 1% = 0,511, 5% = 0,386.

Pela inspeção do gráfico da série do ICMS identificamos o período de julho/2000 a junho/2001 como de pronunciada instabilidade na variância da série. Com o objetivo de melhorar as previsões a partir do modelo a ser gerado, será definido um novo intervalo amostral excluindo as observações até junho/2001. A estimação dos coeficientes e o teste ADF dos resíduos, para o modelo de longo prazo projetado a partir do intervalo de jul/2001 a dez/2009 são apresentados abaixo (tabela 21), após as reduções sugeridas:

Tabela 21: Parâmetros da Eq. de Longo Prazo e teste ADF para os Resíduos

Dependent Variable: LICMS
Method: Least Squares
Date: 11/03/10 Time: 11:05
Sample: 2001M07 2009M12
Included observations: 102
White Heteroskedasticity-Consistent Standard Errors & Covariance

Null Hypothesis: RESIDEQLP has a unit root
Exogenous: None
Lag Length: 1 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.
Augmented Dickey-Fuller test statistic	-4.011180	0.0001
Test critical values:	1% level	-2.588292
	5% level	-1.944072
	10% level	-1.614616

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(RESIDEQLP)
Method: Least Squares
Date: 11/03/10 Time: 15:32
Sample (adjusted): 2001M09 2009M12
Included observations: 100 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESIDEQLP(-1)	-0.420973	0.104950	-4.011180	0.0001
D(RESIDEQLP(-1))	-0.275060	0.097335	-2.825922	0.0057

R-squared	0.344206	Mean dependent var	-1.16E-05
Adjusted R-squared	0.337515	S.D. dependent var	0.095942
S.E. of regression	0.078090	Akaike info criterion	-2.242103
Sum squared resid	0.597614	Schwarz criterion	-2.190000
Log likelihood	114.1052	Durbin-Watson stat	2.132189

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.017946	0.359189	2.834015	0.0056
LVIMP	0.093031	0.042482	2.189909	0.0309
LIVABF	0.288788	0.087821	3.288351	0.0014
LINEF	1.916289	0.169974	11.27399	0.0000

R-squared	0.950228	Mean dependent var	12.79435
Adjusted R-squared	0.948704	S.D. dependent var	0.395077
S.E. of regression	0.089479	Akaike info criterion	-1.951195
Sum squared resid	0.784640	Schwarz criterion	-1.848255
Log likelihood	103.5109	F-statistic	623.6581
Durbin-Watson stat	1.161985	Prob(F-statistic)	0.000000

A equação de longo prazo estimada apresenta *t*-valores significativos para todos os coeficientes, o que juntamente com a análise dos resíduos, concorda com a relação de cointegração constatada entre as séries explicativas e a série LICMS e, portanto, podemos apresentar a relação de longo prazo como um modelo consistente estatisticamente da seguinte forma:

$$\text{LICMS} = 1,017946 + 0,093031 \cdot \text{LVIMP} + 0,288788 \cdot \text{LIVABF} + 1,916289 \cdot \text{LINEF}$$

Para analisar a coerência da presença das variáveis no modelo, foi calculada a matriz de correlação de todas as variáveis $I(1)$ na qual foram incluídas, além das séries em nível, mais doze defasagens de cada uma.

Tomando-se como critério de seleção as correlações com valores acima de 0,90, constatou-se que apenas as séries LICMS, LVIMP, LIVABF e LINEF satisfizeram essa condição, confirmando a coerência da especificação do modelo a partir das análises efetuadas.

5.5 Reparametrização e Redução

Conforme Engle e Granger (1987), se existir uma relação de equilíbrio de longo prazo entre as séries, comprovada pelos testes de cointegração, é razoável tratar o termo de erro como “erro de equilíbrio”, que pode ser usado para ligar o comportamento da arrecadação do ICMS de curto prazo com seu valor em longo prazo.

Como as séries são cointegradas, será possível reparametrizar o modelo específico de longo prazo para um modelo de curto prazo incorporando-se o mecanismo de correção do erro (MCE), popularizado por Engle e Granger, que corrige quanto ao desequilíbrio, (GUJARATI, 2000).

Para iniciar o processo de reparametrização e redução foi construído um modelo de regressão dinâmica a partir da equação de equilíbrio com todas as variáveis em diferenças, no qual foram incorporadas doze defasagens para cada uma das variáveis explicativas do modelo e juntando-se a estas as doze defasagens da variável dependente endógena e seis defasagens do termo de erro da equação de equilíbrio de longo prazo.

É usualmente sugerido na literatura que a estrutura de defasagens seja coerente com a periodicidade dos dados, que neste caso são mensais e por isso são usadas

doze defasagens para captar todas as influências dinâmicas eventualmente presentes no processo. O termo constante deve também ser incluído na regressão entre as variáveis exógenas porque ele representa a origem da relação empírica estimada, (INSEL, 2003).

A equação foi regredida pelo método dos mínimos quadrados ordinários (MQO) e sucessivamente reduzida até a obtenção de um modelo parcimonioso. A formulação do modelo se deu, portanto, do amplo para o restrito, ou seja, retirando-se do modelo geral gradativamente aquelas defasagens não significativas.

No processo de redução do modelo geral para a obtenção da forma específica foi considerada a significância da estatística *t* para cada coeficiente estimado. As variáveis cujos coeficientes apresentaram *t*-valores absolutos menores que os tabulados para um grau de 5% de significância foram sucessivamente eliminados e o modelo reestimado. A estatística *F* é usada para testar a significância global da equação estimada e conjuntamente com *t* visam à minimização dos critérios de Schwarz (SIC) e Akaike (AIC).

Os modelos foram calculados para o intervalo amostral de jul/2001 a dez/2009, com o software *EViews 5.1*, no qual foi indicada a verificação da consistência do teste de White para a detecção de heteroscedasticidade nos resíduos nos cálculos.

Após sucessivas e exaustivas reduções para a obtenção do modelo mais parcimonioso que apresentasse todos os coeficientes significativos, foi obtido o modelo cujos parâmetros e teste ADF para os resíduos são apresentados na tabela 22.

Tabela 22: Parâmetros da Eq. de Curto Prazo e teste ADF para os Resíduos

Dependent Variable: DLICMS
Method: Least Squares
Date: 11/09/10 Time: 13:01
Sample (adjusted): 2001M10 2009M12
Included observations: 99 after adjustments
White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLICMS(-1)	-0.697771	0.129830	-5.374512	0.0000
DLICMS(-2)	0.390075	0.189410	2.059428	0.0423
DLVIMP(-1)	0.171660	0.036460	4.708227	0.0000
DLVABF	0.280927	0.064721	4.340590	0.0000
DLVABF(-1)	0.356649	0.069777	5.111283	0.0000
MCE(-2)	-0.853221	0.184406	-4.626863	0.0000
MCE(-3)	0.619908	0.186164	3.329906	0.0013

R-squared0.544882Mean dependent var0.011452

Adjusted R-squared0.515200S.D. dependent var0.091065

S.E. of regression0.063406Akaike info criterion-2.610422

Sum squared resid0.369874Schwarz criterion-2.426929

Log likelihood136.2159Durbin-Watson stat2.102384

Null Hypothesis: RES has a unit root
Exogenous: None
Lag Length: 0 (Automatic based on SIC, MAXLAG=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.52526	0.0000
Test critical values:		
1% level	-2.588772	
5% level	-1.944140	
10% level	-1.614575	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(RES)
Method: Least Squares
Date: 11/09/10 Time: 14:14
Sample (adjusted): 2001M11 2009M12
Included observations: 98 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RES(-1)	-1.061703	0.100872	-10.52526	0.0000

R-squared0.533075Mean dependent var0.001218

Adjusted R-squared0.533075S.D. dependent var0.089527

S.E. of regression0.061176Akaike info criterion-2.739978

Sum squared resid0.363021Schwarz criterion-2.713600

Log likelihood135.2589Durbin-Watson stat1.956857

A equação de curto prazo com a incorporação do mecanismo de correção de erros será então dada pela fórmula:

$$\begin{aligned} \text{dlog(ICMS)} = & - 0,697771 \cdot \text{DLICMS}(-1) + 0,390075 \cdot \text{DLICMS}(-2) + 0,171660 \cdot \text{DLVIMP}(-1) + \\ & 0,280927 \cdot \text{DLIVABF} + 0,356649 \cdot \text{DLIVABF}(-1) - 0,853221 \cdot \text{MCE}(-2) + \\ & 0,619908 \cdot \text{MCE}(-3) \end{aligned}$$

Pode-se concluir que as variações no log da arrecadação do ICMS podem ser explicadas consistentemente através das suas próprias variações nos dois meses anteriores, da variação do log das importações no mês anterior, da variação do log da arrecadação sobre alimentos, bebidas e fumo atual e do mês anterior e corrigida pelas segunda e terceira defasagens do erro da equação de longo prazo. Observa-se que o sinal negativo resultante dos termos de correção de erro está compatível com a teoria, indicando o ajuste do modelo à tendência definida pela equação de longo prazo.

5.6 Testes de Especificação e Previsões

A correta especificação de um modelo dinâmico é verificada pela análise do termo de erro u_t , que deverá constituir um processo ruído branco (GRANGER; NEWBOLD, 1986). Dessa forma, a verificação da adequabilidade do modelo é efetuada nas autocorrelações amostrais dos erros u_t , que devem seguir assintoticamente uma distribuição normal, com média zero e variância constante, se forem provenientes de um ruído branco. Como os erros verdadeiros (e_t) não são conhecidos, a inferência baseia-se nas estimativas dos erros, os resíduos u_t . Se o modelo estiver corretamente especificado, os resíduos não devem apresentar correlação serial, o que indica que a dinâmica dos dados já foi capturada pelo modelo. Os testes serão avaliados para um nível de significância de 5%. O modelo de curto prazo obtido apresenta todos os regressores estatisticamente significativos ao nível de 1% de significância.

Para a verificação da existência de autocorrelação serial foi executado o teste de Breusch-Godfrey LM, que tem como hipótese nula a inexistência de correlação serial nos resíduos, tendo apresentado $p=0,48$ para três defasagens e $DW=2,10$, portanto, não podemos rejeitar a hipótese nula de que não há correlação serial nos resíduos.

Para exame do comportamento da variância e sob a hipótese nula de que não há heteroscedasticidade nos resíduos, foi aplicado o teste de White, resultando no valor de $p = 0,12$ para a estatística F, indicando que não devemos rejeitar a hipótese nula de variância estável no tempo para o intervalo considerado.

Para a verificação de erro de especificação no modelo, o teste RESET de Ramsey, com duas defasagens, sob a hipótese nula de que não há má especificação no modelo, apresentou $p = 0,70$, garantindo que o modelo está bem especificado para o nível de significância considerado.

Por fim, a verificação da normalidade da distribuição dos resíduos foi testada através do teste de Jarque-Bera sob a hipótese nula de normalidade dos resíduos, resultando $JB=2,08$ e $p=0,35$, atestando a aceitação da hipótese nula da distribuição normal dos resíduos.

Além da conclusão pela normalidade dos resíduos; pelo resultado do teste de White para a verificação de presença de heteroscedasticidade, concluímos que os resíduos da equação de curto prazo estimada são homoscedásticos. Os estimadores de mínimos quadrados ordinários para os parâmetros são não-tendenciosos, consistentes e eficientes, isto é, as variâncias dos parâmetros estimados são as variâncias mínimas e, além disso, serão estimadores não tendenciosos da verdadeira variância dos parâmetros estimados, (PINDICK; RUBINFELD, 2004).

No Apêndice A são apresentadas as tabelas com os resultados dos respectivos testes efetuados para os resíduos da equação de curto prazo.

5.6.1 Previsões

A previsão de uma série temporal é simplesmente o estabelecimento dos valores futuros da série. Uma previsão é uma estimativa quantitativa (ou conjunto de estimativas) acerca da verossimilhança de eventos futuros, baseados na informação atual e passada, e está associada à arte de decidir qual modelo construir, (BRASIL, G. H., 2009, UFES).

Os valores para as previsões utilizando a equação de curto prazo foram obtidos mediante o software *EViews 5.1* no intervalo de jan/2010 a ago/2010 para comparações com os valores reais arrecadados já disponíveis.

O modelo de curto prazo utiliza como variáveis exógenas as duas primeiras defasagens da variável dependente DLICMS, a primeira defasagem de DLVIMP, o valor atual e a primeira defasagem da variável DLIVABF, além da segunda terceira defasagens da série dos resíduos da equação de longo prazo. Explicitando LICMS na equação temos:

$$\text{LICMS} = \text{LICMS}(-1) - 0,69777 \cdot \text{DLICMS}(-1) + 0,39007 \cdot \text{DLICMS}(-2) + 0,17166 \cdot \text{DLVIMP}(-1) + 0,28093 \cdot \text{DLIVABF} + 0,35665 \cdot \text{DLIVABF}(-1) - 0,85322 \cdot \text{MCE}(-2) + 0,61991 \cdot \text{MCE2}(-3)$$

$$\text{ICMS} = \text{EXP}(\text{LICMS})$$

Foi executada a modalidade dinâmica de previsão disponível no *EViews 5.1*, que dentro do intervalo de previsão faz uso dos valores previstos da variável endógena no período anterior para o cálculo dos valores subsequentes. Esta modalidade é empregada em *forecasting* fora da amostra quando os valores realizados não estarão disponíveis. Neste caso, será necessária ainda a obtenção das previsões para as demais variáveis explicativas presentes no modelo mediante a utilização de qualquer método adequado, sendo o modelo ARIMA o mais comumente utilizado.

Como critério de verificação da acurácia do modelo, foi empregado o erro percentual absoluto médio que, considerando a estabilidade da variância dos resíduos do modelo, trata todos os erros com o mesmo peso e é dado pela seguinte expressão:

$$EPAM = \frac{100}{n} \cdot \sum_{t=1}^n \frac{|e_t|}{Y_t}$$

Onde n é o número de observações do intervalo de previsão e $|e_t|$ é o erro absoluto de previsão ($|e_t| = Y_t - \hat{Y}_t$).

A obtenção das previsões pelo método dinâmico do *EViews 5.1* requer que os dados para as variáveis exógenas estejam previstos para cada período do intervalo de previsão e que os valores da variável dependente defasada sejam conhecidos no início do mesmo intervalo.

A previsão dinâmica pode ser interpretada como uma previsão calculada recursivamente utilizando a informação disponível no início do intervalo. Por isso a

seleção do início do intervalo é muito importante no método dinâmico. Na Previsão de equações com componentes ARMA, por padrão o *EViews* irá prever valores para os resíduos utilizando a estrutura ARMA indicada, (*Eviews User Guide 5.1*, p. 540).

Os valores previstos das variáveis explicativas DLVIMP e DLIVABF e do mecanismo de correção de erro MCE para o intervalo de previsão foram obtidos pela construção de modelos com a metodologia Box-Jenkins, cujos resíduos foram testados e apresentaram características de ruído branco. A representação dos modelos ARIMA ajustados para o intervalo de jul/2001 a dez/2009 são apresentados abaixo e suas respectivas tabelas constam do Apêndice A.

VARIÁVEL	MODELO ARIMA
DLVIMP	MA(1) MA(2)
DLIVABF	AR(1) AR(3) SAR(12) MA(12)
MCE	AR(1) AR(2) AR(3)

As séries explicativas utilizadas no modelo dinâmico para curto prazo foram obtidas mediante a previsão dos respectivos valores para o intervalo de jan/2010 a ago/2010. O *EViews 5.1* mantém os dados realizados até o período anterior e completa a série com os valores da previsão dinâmica. Essas séries contendo as estimativas para o intervalo de previsão é que serão utilizadas para o cálculo dinâmico da variável dependente. As novas séries acrescidas dos valores previstos foram denominadas DLVIMPF, DLIVABFF e MCEF.

A representação do modelo utilizado para o cálculo das previsões dinâmicas será:

$$\begin{aligned} \text{dLOG(ICMS)} = & - 0,697771 * \text{DLOG(ICMS(-1))} + 0,390075 * \text{DLICMS(-2)} + \\ & 0,171660 * \text{DLVIMPF(-1)} + 0,280927 * \text{DLIVABFF} + \\ & 0,356649 * \text{DLIVABFF(-1)} - 0,853221 * \text{MCEF(-2)} + \\ & 0,619908 * \text{MCEF(-3)} \end{aligned}$$

Os valores das previsões obtidos pelo modelo de curto prazo com incorporação do mecanismo de correção de erros são apresentados na tabela 23 conjuntamente com os valores realizados para o ICMS no período de jan/2010 a ago/2010.

A tabela 23 apresenta as previsões de curto prazo utilizando a método dinâmico. Esta forma é empregada para a estimativa de valores fora da amostra, quando não

há dados disponíveis para os componentes exógenos do modelo, que são calculados utilizando-se os respectivos modelos ARIMA ajustados.

Tabela 23: Valores da Previsão Dinâmica do Modelo de Curto Prazo

MÊS	PREVISÃO	ICMS	ERRO ABS	EPA	EPAM
jan/10	608.791,42	584.483,00	24.308,42	4,16	4,16
fev/10	581.651,65	559.227,00	22.424,65	4,01	4,08
mar/10	614.073,56	566.365,00	47.708,56	8,42	5,53
abr/10	600.007,84	594.098,00	5.909,84	0,99	4,40
mai/10	616.617,39	574.263,00	42.354,39	7,38	4,99
jun/10	589.885,07	515.454,00	74.431,07	14,44	6,57
jul/10	621.151,32	494.118,00	127.033,32	25,71	9,30
ago/10	599.289,46	528.081,00	71.208,46	13,48	9,82
EPAM				9,82	

EPA: Erro percentual absoluto

EPAM: Erro percentual absoluto médio

Pode-se observar que o erro percentual absoluto aumenta a partir do mês de abril. Essa diferença pode ser explicada pelos seguintes motivos. As previsões obtidas para as variáveis explicativas acumulam erros que são propagados através da equação de curto prazo. Ademais, conforme o *User Guide* do software *EViews*, os dados do último período antes do intervalo de *forecasting* influenciam diretamente os resultados de previsão dinâmica. Pela observação do gráfico do ICMS constata-se que no segundo semestre de 2009 a arrecadação apresentou crescimento, o que induziu a previsão dinâmica de valores superiores aos observados para o período de *forecasting* e que a partir de abril/2010 a arrecadação voltou a declinar motivada possivelmente por fatores conjunturais não captados pelo modelo. Daí o aumento dos valores do EPA verificado de maio a agosto/2010.




Gráfico 26: Previsões e avaliação do modelo econométrico

O gráfico 26 apresenta as séries ICMSF e ICMS; respectivamente as previsões e os valores realizados do ICMS para o intervalo de jan/2010 a ago/2010 acompanhado do respectivo relatório de previsão.

6. CONCLUSÃO

6.1 Considerações Gerais

O objetivo geral deste trabalho foi a análise dos dados de série temporal da arrecadação do ICMS (Imposto sobre Circulação de Mercadorias e Serviços) do estado do Espírito Santo para elaboração de modelos para previsão de receitas tributárias.

Por princípio, as previsões baseadas em dados de séries temporais pressupõem que as séries sejam estacionárias, o que implica que, nas mesmas condições, a série deverá repetir no futuro aproximadamente o mesmo padrão de comportamento observado no passado.

Sabemos que os dados de natureza econômica quando utilizados para previsão, pela quantidade de fatores que podem influenciá-los, geram dificuldades que requerem uma criteriosa escolha das fontes dos dados, das variáveis que serão consideradas relevantes para a pesquisa e do método a ser utilizado para escolha do modelo.

Os dados das receitas mensais da arrecadação tributária do ICMS utilizados nesta pesquisa correspondem aos consolidados pelo Ministério da Fazenda através da Comissão Técnica Permanente do ICMS, disponibilizados no portal do Banco Central do Brasil. Esses dados já contabilizam os recolhimentos relativos às operações interestaduais, razão pela qual apresentam valores maiores em relação aos disponíveis no portal da Secretaria Estadual de Fazenda do Espírito Santo.

Para a escolha das variáveis relevantes que caracterizam a base de cálculo do imposto, foram levados em consideração os arranjos econômicos setoriais e o perfil de desenvolvimento do estado do Espírito Santo, que apresenta significativo desenvolvimento nos setores de comércio exterior, industrial e de serviços.

Quanto à escolha da metodologia, podemos afirmar que nenhum método pode ser considerado como o melhor para fazer previsões em qualquer circunstância, apresentando cada um as suas vantagens e desvantagens, o que torna o procedimento de previsão uma tarefa complexa e de difícil execução.

6.2 Avaliação dos modelos

Para este trabalho foram escolhidos três modelos extrapolativos, sendo um destes com intervenção mediante função de transferência, e um modelo econométrico causal. A tabela 24 relaciona os métodos utilizados e um resumo das vantagens e desvantagens de cada um.

Tabela 24: Características dos Métodos Utilizados

MÉTODO	VANTAGENS	DESVANTAGENS
Alisamento exponencial de Holt	Fácil entendimento. Aplicação simples. Grande flexibilidade. Poucos dados.	Dificuldade em determinar os valores mais apropriados das duas constantes de alisamento.
Alisamento exponencial Holt-Winters (aditivo e multiplicativo)	Fácil entendimento. Aplicação simples. Grande flexibilidade. Análise de séries com comportamento mais geral.	Dificuldade em determinar os valores mais apropriados das três constantes de alisamento. Dificuldade na construção de intervalos de confiança.
Box-Jenkins	A flexibilidade permite identificar mais facilmente os padrões da série. O princípio da parcimônia permite a construção de modelos mais simples.	Complexidade e dificuldade de entender. A flexibilidade é uma desvantagem caso os padrões identificados não persistam em período a ser previsto.
Box-Jenkins com intervenção	Útil para mensurar o efeito de eventos externos sobre a série.	O uso da forma específica depende da conveniência e da interpretação do evento.
Econométrico	Podem se confiáveis para estabelecer relações causais. Podem se usados para o estabelecimento de políticas.	Difícil de desenvolver. Requer grande quantidade de dados. Definição de variáveis exógenas.

Fonte: MORETIN;TOLOI (2006), WEI (1994), FILDES (2010).

A arrecadação do ICMS para o período amostral base da série temporal em estudo, de jan/2000 a dez/2009, apresenta a partir do mês de dez/2008 os efeitos da crise econômica mundial na economia brasileira em forma de queda significativa e que se propagou ao longo de todo o ano de 2009, o que afetou a acurácia das previsões e sugeriu a escolha de um modelo com intervenção para reproduzir o evento. Embora a intervenção proporcionada pela crise tenha adicionado um complicador na análise,

a mesma representou uma oportunidade para testar modelos alternativos adequados que incorporam a intervenção observada.

A fim de demonstrar e comparar o desempenho dos modelos de alisamento de Holt e Holt-Winters e do modelo estocástico de Box-Jenkins, para períodos antes da crise e depois da crise financeira e, portanto, sem e com a presença de intervenções, respectivamente, foram estimados os modelos tomando como base o período de jan/2000 a dez/2007, com previsões para jan/2008 até ago/2008. A tabela 25 apresenta os erros percentuais absolutos médios acumulados para cada mês do período de previsão.

Tabela 25: Erros de Previsão para Período sem Intervenção

MÊS	EPAM (JAN →) acumulado			
	Holt	HWSA	HWSM	BJ
Jan/08	5,83	4,45	0,43	4,30
Fev/08	4,37	2,47	0,53	5,31
Mar/08	5,13	2,55	2,17	6,83
Abr/08	4,81	2,15	1,64	6,93
Mai/08	4,86	2,02	2,25	7,37
Jun/08	4,11	2,32	2,51	6,76
Jul/08	4,08	2,17	2,61	7,01
Ago/08	3,94	2,80	3,37	6,37

Fonte: Cálculos no Software *EViews 5.1*

Os erros médios para todos os períodos calculados demonstram que as previsões para 2008, na ausência de perturbações externas na série, os resultados são mais acurados, o que em comparação com 2009, recomenda a escolha de metodologia que considere eventos externos e ajude a explicar a queda na eficiência dos modelos para os períodos posteriores a 2008.

A tabela 26 apresenta os erros de previsão para cada um dos modelos calculados. A medida da acurácia das previsões foi feita por meio da utilização do erro percentual absoluto médio (EPAM) atualizado para cada período até o mês de agosto de 2010.

Tabela 26: EPAM Acumulados para os Modelos Calculados.

MÊS	EPAM (JAN →) acumulado					
	Holt	HWSA	HWSM	BJ	BJ I	ECON
Jan/10	0,55	1,69	5,29	0,55	3,37	4,16
Fev/10	3,09	1,74	3,12	3,82	6,33	4,08
Mar/10	3,68	1,47	2,22	5,42	5,16	5,53
Abr/10	2,88	1,72	2,58	4,90	5,47	4,40
Mai/10	3,21	1,75	3,10	5,56	7,02	4,99
Jun/10	5,51	3,68	4,69	8,32	6,85	6,57
Jul/10	7,97	5,77	6,28	11,19	6,96	9,30
Ago/10	8,90	6,44	6,65	12,47	6,77	9,82

Fonte: Cálculos no Software *EViews 5.1*

Os modelos de alisamento, são considerados modelos intuitivos e representam tentativas de se determinar uma espécie de “média” em torno da qual as observações flutuam. O alisamento exponencial calcula uma média ponderada das observações anteriores, em que os pesos diminuem à medida que a observação se afasta da atual. Observa-se na tabela, que esses modelos produzem bons ajustamentos e consequentemente boas previsões até cinco períodos à frente, em regra com erro médio abaixo de 4%. Portanto, consistentes quanto à sua eficiência para fazer previsões, uma vez que se observa um bom ajuste entre estas e os valores observados para a arrecadação do ICMS.

A metodologia de Box-Jenkins fornece um modelo puramente estocástico que procura captar as características essenciais do processo em estudo e subjacentes à série temporal. É particularmente adequado para o desenvolvimento de modelos para séries com comportamento sazonal e pode apresentar alta precisão em previsões para o curto prazo, até três meses à frente. Os resultados das previsões do ICMS começam a deteriorar a partir do mês de março/2010 e o erro médio eleva-se para 12,47% no intervalo de oito meses. Esse fato é normalmente observado em séries com componentes sazonais ou que apresentam choques externos que geram flutuações no gráfico. Nesses casos os parâmetros do modelo devem ser monitorados e periodicamente de modo a levar em conta essas alterações.

Particularmente no caso do ICMS, observa-se que a arrecadação a partir do mês de maio/2010 inverte a tendência de recuperação e cai por três meses consecutivos, o que contribuiu para o aumento do erro verificado.

A introdução de função de transferência no modelo Box-Jenkins para reproduzir a quebra verificada no gráfico em dez/2008, resultou em uma redução de 46% do EPAM no período total de oito meses de previsão, embora no curto prazo não tenha ganhado eficiência em relação do modelo Box-Jenkins puro.

O modelo econométrico é uma tentativa de relacionar o comportamento da arrecadação do ICMS com o de outras variáveis. As variáveis escolhidas como importantes para o modelo e a própria estrutura do mesmo são sugeridas pela teoria econômica. O termo econométrico indica uma estrutura especial ditada pela análise do contexto econômico local.

A construção de modelos econométricos requer conhecimento das relações entre as variáveis consideradas importantes para a formação da receita. Além do mais, essas variáveis podem ser de difícil identificação e necessitarem de previsões cujos erros repercutirão nos valores previstos para a variável dependente.

Quanto aos erros de previsão, verifica-se na tabela 26 que há uma tendência do aumento dos erros medidos pelo EPAM à medida que se aumenta a amplitude do intervalo de previsão. Observa-se que para previsões de curto prazo, consideradas até três períodos à frente, os modelos apresentam excelente desempenho preditivo. O aumento dos erros pode ser atribuído a várias causas, desde as de natureza endógena, não captadas pelos modelos, até as resultantes de instabilidades econômicas, ações de administração fiscal ou políticas de regimes tributários especiais.

Observamos que a acurácia das previsões tende a ser melhor no horizonte de curto prazo, considerado nos três primeiros meses de previsão, com destaque para os modelos de alisamento exponencial, que apresentam erros de previsão abaixo de 5% até seis meses à frente, conforme a tabela 26 acima.

Os modelos ARIMA e ARIMA com intervenção, baseados na metodologia de Box-Jenkins, cuja construção procura captar e reproduzir os padrões observados na série, apresentaram resultados melhores que os do modelo causal no curto prazo. Tal resultado pode ser atribuído ao grau de causalidade das variáveis explicativas escolhidas para este modelo e ao fato de todas as séries explicativas integrantes do modelo econométrico terem sido afetadas pelo impacto da crise mundial, com efeito sobre as relações de cointegração e alterando o desempenho do modelo.

Os padrões históricos das séries econômicas geralmente são alterados por fatores não captados por modelos de natureza puramente quantitativa, uma vez que a conjuntura econômica, decisões políticas e ações administrativas tributárias tendem a alterar significativamente o resultado da arrecadação. Apesar disso, a abordagem de séries temporais, via de regra, apresenta melhor performance que a baseada na modelagem causal, notadamente no curto prazo, em vista da incerteza associada à captura de todos os fatores econômicos relevantes que influenciam a geração da receita, (Frank, 1993). Segundo Makridakis *et al.* (1984), os métodos quantitativos simples executam estimativas tão boas quanto os métodos mais complexos.

A receita bruta do ICMS-ES embora tenha atingido um recorde nominal no ano de 2010, segundo o Boletim Fiscal nº 4/2010, da Secretaria de Estado da Fazenda (SEFAZ), ainda não recuperou a tendência histórica observada antes da crise mundial iniciada em 2008, podendo inclusive ser constatado no gráfico 27, que houve uma queda na arrecadação nos meses de abril a julho, exatamente no período utilizado para controle das previsões dos modelos utilizados no trabalho, o que certamente diminuiu a eficiência das estimativas.




Gráfico 27: Arrecadação do ICMS no ano de 2010

Pelos resultados do teste de causalidade de Granger apresentados na tabela 19 e pela análise do comportamento das séries explicativas apresentados no gráfico 24 podemos inferir que as séries do valor das importações e do índice de produção industrial foram as que causaram maior impacto na série dependente e contribuíram significativamente para a queda da arrecadação e a conseqüente alteração estrutural na série do ICMS.

Outra forma de comparar o impacto de cada série explicativa, integrante do modelo de longo prazo, sobre a arrecadação é mediante o cálculo do coeficiente *beta* de cada variável, definido como o novo coeficiente obtido quando todas as variáveis são expressas na forma padronizada, ou seja, subtraindo de cada variável o seu valor médio e o dividindo o resultado pelo seu respectivo desvio padrão.

A vantagem de se utilizar um modelo de regressão padronizado é que podemos utilizar os coeficientes *beta* para comparar diretamente o impacto de cada variável explicativa sobre a variável regredida. Existe uma interessante relação entre os coeficientes β do modelo convencional e os coeficientes *beta* do modelo padronizado, Gujarati (2006). Para um modelo bivariado com variáveis *Y* e *X* a relação é:

$$\hat{\beta}^* = \hat{\beta} \cdot \left(\frac{S_x}{S_y} \right), \text{ onde } S_x \text{ é o desvio padrão amostral do regressor } X \text{ e } S_y \text{ é o desvio}$$

padrão amostral da variável regredida *Y*.

Considerando o modelo convencional de longo prazo calculado para a arrecadação, LICMS = 1,017946 + 0,093031. LVIMP + 0,288788. LIVABF + 1,916289. LINEF.

Teremos o seguinte modelo padronizado correspondente:

$$\text{LICMS}^* = 0,12666. \text{LVIMP}^* + 0,17053. \text{LIVABF}^* + 0,70120. \text{LINEF}^*$$

A interpretação aqui é que se qualquer das séries explicativas variar de um desvio padrão, a série LICMS variará de uma quantidade de desvios padrão igual ao respectivo coeficiente *beta*. Logo, a série que mais influência tem na arrecadação no longo prazo é LINEF, vindo em seguida LIVABF e depois LVIMP, o que é razoável tendo em vista que a série LINEF é a mais estável delas, conforme pode ser visto no gráfico 8.

6.3 Recomendações

Este trabalho sobre modelos de previsão para a arrecadação do ES demonstra a complexidade da tarefa de definir qual o modelo mais adequado para ser utilizado na previsão de qualquer variável econômica, principalmente daquelas cuja cadeia de formação envolve toda uma conjuntura econômica a ser considerada.

Não obstante as dificuldades e a amplitude de aplicação que cercam esse assunto, a elaboração de modelos para *forecasting* é um campo de interesse crescente, cujas possibilidades aumentam com o uso de ferramentas de softwares cada vez mais eficientes e com a demanda por dados para fins gerenciais.

Em vista do que foi exposto neste trabalho, não podemos definir apenas um modelo como adequado para as previsões de receita do ICMS. Temos que levar em conta o horizonte de previsão requerido e o comportamento recente da série, pelo menos nos 50 períodos anteriores.

Para previsões de curto prazo em períodos de relativa estabilidade econômica, os modelos de alisamento exponencial de Holt-Winters apresentam excelentes resultados práticos, dada as suas características matemáticas, simplicidade e grande flexibilidade.

Para estimativas de médio prazo, considerado de três a doze meses à frente, os modelos estocásticos de Box-Jenkins apresentam boa eficiência pela sua capacidade de captar e reproduzir o comportamento estrutural da série no período amostral considerado.

Os modelos econométricos, apesar das dificuldades de desenvolvimento apresentadas, podem ser aplicados tanto no médio quanto no longo prazo para definição de políticas e planejamento governamental, desde que as variáveis causais sejam relevantes e bem identificadas e existam dados na qualidade e quantidade necessárias. Além disso, podem ser verificados cenários alternativos.

As previsões resultantes dos modelos calculados apresentam resultados significativamente melhores que as projeções simples ou de linha de tendência e as estimativas qualitativas conservadoras baseadas no crescimento do PIB nacional. Sugere-se a adoção pela SEFAZ-ES de um dos modelos apresentados neste trabalho, recomendando-se que o modelo seja revisto periodicamente com monitoramento permanente para atualização dos parâmetros do modelo, visando incorporar os efeitos de ações fiscais e de mudanças econômicas,.

A qualidade das previsões do modelo econométrico recomenda uma pesquisa mais cuidadosa das variáveis referentes ao setor de serviços, para a inclusão no modelo dinâmico. O uso de combinações de previsões com a utilização de diferentes modelos ou modelos mistos, aproveitando as vantagens de modelos de séries

temporais e de modelos econométricos também poderão ser desenvolvidos para a obtenção de maior eficiência preditiva.

A técnica de análise com funções de transferência para captar eventuais intervenções na série temporal poderá ser testada com modelos econométricos, caso estes sejam escolhidos como adequados à variável em estudo.

Para a obtenção de previsões das variáveis explicativas exógenas, no caso do uso de modelos econométricos, poderão ser analisados cenários econômicos a partir de avaliações qualitativas realistas, com base nas informações disponíveis.

7. REFERÊNCIAS

1. AKB, **Dossiê da Crise**, Associação Keynesiana Brasileira, Novembro de 2009. Disponível em: <<http://www.ppge.ufrgs.br/akb>>
2. ALLEN, P. G. & FILDES, R. **Econometric Forecasting**. In J. Scott Armstrong (editor), *Principles of Forecasting: A Handbook for Researchers and Practitioners*, pp. 303-362, Kluwer Academic Press, Norwell, MA, 2001.
3. ARMSTRONG, J. S. **Research Needs in Forecasting**. *International Journal of Forecasting*, p.449-465, vol.4, 1988.
4. ARMSTRONG, J.S. **Long-Range Forecasting From Crystal Ball to Computer**, 2nd edition. New York: John Wiley & Sons, 1985.
5. ARRAES, R. A. e CHUMVICHITRA, P. **Modelos Autoregressivos e Poder de Previsão: Uma Aplicação com o ICMS**. Texto para Discussão nº 152. Programa de Pós-Graduação em Economia, Universidade Federal do Ceará, 1996.
6. BOX, G. E. P. & TIAO, G. C. **Intervention Analysis with Applications to Economic and Environmental Problems**. *Journal of the American Statistical Association*. Vol.70, nº 349 (mar. 1975), pp.70-79.
7. BOX, G. E. P.; JENKINS G. M. & REINSEL, G. C. **Time Series Analysis: Forecasting and Control**, 3rd Revised edition, Holden-day, San Francisco, 1994.
8. BRASIL, G.H. **Estacionariedade, Raízes Unitárias e Cointegração**. Notas de Aula, Universidade Federal do Espírito Santo, 2010.
9. BRASIL, G.H. **Introdução à Análise de Séries Temporais**. Notas de Aula, Universidade Federal do Espírito Santo, 2009.
10. BRASIL. **Constituição da República Federativa do Brasil de 1988**. Brasília, 05 de outubro de 1988.
11. BRASIL. **Lei Complementar nº 101** de 04/05/2000. Dispõe sobre o imposto dos Estados e do Distrito Federal sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação, e dá outras providências. DOU, Brasília, 5 de maio de 2000.
12. BRASIL. **Lei Complementar nº 87** de 13 de setembro de 1996. Dispõe sobre o imposto dos Estados e do Distrito Federal sobre operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação, e dá outras providências. DOU, Brasília, 16 de setembro de 1996.
13. CAMPOS, C.V.C. **Métodos Econométricos Aplicados à Previsão da Arrecadação de Receitas Federais**. Receita Federal do Brasil. ESAF, 2009.

14. CHATFIELD, C. **Times-Series Forecasting**, Department of Mathematical Sciences, University of Bath, UK. Chapman&Hall/CRC, 2000.
15. CHOW, G.C. **Tests of Equality between Sets of Coefficients in Two Linear Regressions**, *Econometrica*, 52, 211-22, (1960)
16. CIRINCIONE, C.; GURRIERI G. A. & SANDE, B. van de. **Municipal Government Revenue Forecasting: Issues of Method and Data**, Public Budgeting and Finance, p.26-46, Spring, 1999.
17. CORVALÃO, E. D. **Previsão da Arrecadação do ICMS em Santa Catarina: Aplicação da Abordagem Geral para Específico em Modelos Dinâmicos**. Dissertação de Mestrado. Universidade Federal de Santa Catarina, 2002. Disponível em: http://www.senado.gov.br/conleg/textos_discussao.htm
18. DORNBUSH, R & FISCHER, S. **Macroeconomia**. 5ª Ed. Editora Makron, McGraw-Hill, 1991.
19. ENGLE, R. F. & GRANGER, C. W. J. **Cointegration and Error Correction: Representation, Estimation and Testing**, *Econometrica*, Vol.55, pp.251-276, 1987.
20. ENGLE, R.F. & GRANGER, C.W.J. **Long Run Economic Relationships: Readings in Cointegration**. Oxford University Press, Oxford, 1991.
21. ESTADO DO ESPÍRITO SANTO. **Lei Complementar Estadual nº 2.508** de 22 de maio de 1970. Instituiu o Fundo para o Desenvolvimento das Atividades Portuárias – FUNDAP.
22. FILDES, R. **Forecasting: The issues**. (Revised Version). Lancaster Centre for Forecasting, UK, jan 2010.
23. FRANK, H. A. **Budgetary Forecasting in Local Government: New Tools and Techniques**. Westport, CT: Quorum Books. 1993.
24. FRIEDMAN, M. **The Methodology of Positive Economics**, Essays in Positive Economics, 1953.
25. GILBERT, C. L. **Practitioners' Corner: Professor Hendry's Econometric Methodology**, *Oxford Bulletin of Economics and Statistics*, Vol.48, pp.283-307, 1986.
26. GRANGER, C. W. J. **Investigating causal relations by econometric models and cross-spectral methods**. *Econometrica*, Vol.37, 424–438, 1969.
27. GRANGER, C.W.J. & NEWBOLD, P. **Forecasting Economic Time Series**. New York: Academic Press, 1986.
28. GRASSI, Robson & CAÇADOR, Sávio. **A Evolução Recente da Economia do Espírito Santo: Um Estado Desenvolvido e Periférico**. Vitória: Grupo de Estudos em Organização Industrial da Universidade Federal do Espírito Santo, 2009.

29. GUJARATI, Damodar N. **Econometria Básica**, São Paulo, Makron Books, 3ª edição, 2000.
30. GUJARATI, Damodar N. **Econometria Básica**, Campus, 1ª edição, 2006.
31. HOLT, C. C. Forecasting Seasonal and Trends by Exponentially Weighted Moving Averages, Office of Naval Research, Research Memorandum No. 52. 1957. http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1054881.
32. HYLLEBERG, S. **Modelling Seasonality**. Oxford University Press, 1992.
33. HYNDMAN, R. J.; KOEHLER, A. B. **Another look at measures of forecast accuracy**. International Journal of Forecasting 22, p.679– 688, 2006.
34. INSEL, Aysu. **Econometric Modelling in Applied Economic Time Series**. Marmara University, Faculty of Economics and Administrative Sciences. Istanbul, 2003.
35. IPEA (2009a), **O que explica a queda recente da receita tributária federal?** Diretoria de Estudos Macroeconômicos, Nota Técnica. Rio de Janeiro, Agosto/2009. Disponível em: http://www.ipea.gov.br/sites/000/2/pdf/090826_NotaTecTribut.pdf
36. IPEA (2009b), **Evolução da Estrutura da Receita Tributária Administrada pela Receita Federal: Por que decresceu muito mais que o PIB?** Texto para discussão nº63, Brasília, Setembro/2009. Disponível em: http://www.senado.gov.br/conleg/textos_discussao.htm
37. IPEADATA. **Dados Socioeconômicos dos Estados e do Brasil para o Período 1970-2007**. Disponível em: www.ipeadata.gov.br.
38. JOHANSEN, S. **Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models**. Econometrica, 59, 1551–1580. 1991.
39. JOHANSEN, S. **Statistical analysis of cointegration vectors**, Journal of Economic Dynamics and Control 12, 231-54. 1988.
40. JOHNSTON, Jack & DINARDO, John. **Econometric Methods**, 4th Ed., McGraw Hill, New York, (International Student Edition), 1997.
41. LEAL, Tereza et al. **Fiscal Forecasting: Lesson from Literature and Challenges**. European Central Bank (ECB), Research Paper Series - Working Papers nr.843, dezembro/2007. Disponível em: <http://www.ecb.int/pub/pdf/scpwps/ecbwp843.pdf>
42. LEAMER, E. E. **Vector Autoregressions for Causal Inference**. In: BRUNNER, K; MELTZER, A. (org.). Understanding Monetary Regimes. In: Journal of Monetary Economics, Supplement, pp. 255-304, 1985.
43. LIEBEL, M. J. **Previsão de Receitas Tributárias: O Caso do ICMS no Estado do Paraná**. Mestrado Universidade Federal do Rio Grande do Sul, 2004.

44. LOPES, A.C.B.S. **Sazonalidade em Séries Temporais Econômicas: Uma Introdução e Duas Contribuições**. Instituto Superior de Economia e Gestão Universidade Técnica de Lisboa, 2007.
45. MACKINNON, J. **Critical values for cointegration tests**. In: ENGLE, R. F.; GRANGER, C. W. J. (Ed.). Long-run economic relationships: readings in cointegration. Oxford: Oxford University Press, 1991.
46. MAKRIDAKIS, Spyros G. *et. al.* **Forecasting: Methods and applications**. 3rd ed. New York: John Wiley & Sons, 1998.
47. MARQUES C.F.A. e UCHOA C.A.G. **Estimação e Previsão do ICMS na Bahia**. II Encontro de Economia Baiana. Setembro/2006.
48. MELO, B. S. V. de. **Modelo de Previsão para a Arrecadação Tributária**. Brasília, 2001. (Mestrado – Universidade de Brasília - UnB)
49. MORETTIN, P. A. e TOLOI, C. M. C. **Análise de Séries Temporais**. 2a. Edição, São Paulo: Blucher, 2006.
50. MORETTIN, P. A. **Econometria Financeira – Um Curso em Séries Temporais Financeiras**, 1ª Edição, São Paulo: Blucher, 2008.
51. OLIVEIRA, J. Teófilo. **O Ajuste Fiscal do Governo do Espírito Santo em 2003**. SEFAZ-ES. Maio/2004.
52. OLIVEIRA, J.T. e DIETZE, B.O.S. **Capacidade de Investimento, Fontes e Usos dos Recursos do Tesouro Estadual – 1997/2003**. SEFAZ-ES. Setembro/2004.
53. PANKRATZ, Alan. **Forecasting With Univariate Box-Jenkins Models**. New York: John Wiley & SONS, 1983.
54. PECEGUINI, E.E. **Análise Comparativa de Métodos de Previsão Aplicados à Arrecadação do ICMS - Estado de São Paulo**. Brasília : ESAF, 2001.
55. PINDYCK, R.S. e RUBINFELD, D.L. **Econometria: Modelos e Previsões**, tradução da quarta edição, Editora Campus, 2004.
56. REZENDE, F. **A Moderna Tributação do Consumo**. Texto para Discussão nº 303, Brasília: IPEA, 1993.
57. RIBEIRO, Lívio. **Modelos Mensal e Trimestral para Projeção de Arrecadação do ICMS para o Estado do Espírito Santo**. Instituto Jones dos Santos Neves. Texto para Discussão nº.10. Vitória-ES, 2009.
58. RICMS/ES. Espírito Santo. **Dec. nº1.090-R**, de 25/10/2002. Regulamento do Imposto sobre Operações Relativas à Circulação de Mercadorias e sobre Prestações de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação. DOE: 25/10/2002.
59. SANTOS, A.V. e COSTA, J.H.F. **Análise de Modelos de Séries Temporais para a Previsão Mensal do ICMS do Estado do Maranhão para Ano de 2008**.

Cadernos IMESC – Instituto Maranhense de Estudos Socioeconômicos e Cartográficos, 2008.

60. SEFAZ-ES, Gerência de Arrecadação e Informática. **Relatório Gerencial**. Agosto/ 2007.
61. SEFAZ-ES. **Balancete Geral**. Dados até março de 2010.
62. SEFAZ-ES. Secretaria de Estado da Fazenda Espírito Santo. **Relatório Gestão 2003-2006**.
63. SIQUEIRA, M. L. **Modelos de Séries Temporais para a Previsão da Arrecadação Tributária Federal**. Dissertação de Mestrado. Universidade Federal de Pernambuco, 2002.
64. WEI, William W. S. **Time Series Analysis, Univariate and Multivariate Methods**, Addison-Wesley Publishing Company. 2th edition, 1994.
65. WINTERS, P. R. **Forecasting Sales by Exponentially Weighted Moving Average**. Management Science, Vol. 6, 324-342, 1960.

8. APÊNDICE A

8.1 Tabela de dados da arrecadação do ICMS

Arrecadação de ICMS - Espírito Santo - u.m.c. (mil)

Mês	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
jan	179.589	255.968	175.360	222.164	304.256	366.208	420.817	493.087	576.361	621.235	584.483
fev	160.949	192.013	172.458	243.554	267.499	344.015	398.454	471.378	532.407	581.036	559.227
mar	151.556	264.660	221.746	224.287	249.811	369.519	370.908	420.351	518.594	490.115	566.365
abr	170.999	164.442	181.090	227.645	309.618	392.448	432.688	472.820	537.435	578.135	594.098
mai	150.580	167.610	184.096	241.965	279.336	393.321	379.309	440.555	536.292	532.091	574.263
jun	143.875	253.532	181.448	254.718	293.702	390.573	416.988	468.596	570.683	538.086	515.454
jul	169.678	195.181	189.471	221.940	314.863	378.628	414.504	488.660	552.024	591.843	494.118
ago	152.734	198.374	215.276	231.651	336.993	384.444	419.380	498.165	596.203	509.130	528.081
set	157.909	200.328	213.338	239.250	307.270	409.712	441.338	503.980	623.042	514.542	563.517
out	160.378	186.353	184.653	285.209	346.225	398.860	446.314	518.192	602.983	530.039	700.364
nov	170.711	210.728	241.193	280.180	340.966	379.098	463.108	554.304	629.723	561.732	612.582
dez	235.573	201.329	221.488	261.953	381.463	428.792	487.799	548.380	725.522	622.475	672.293

Fonte MF-Cotepe

8.2 Tabelas contendo os termos sazonais dos modelos Holt-Winters

Holt-Winters Sazonal Aditivo

Date: 02/14/11 Time: 10:08
Sample: 2000M01 2009M12
Included observations: 120
Method: Holt-Winters Additive Seasonal
Original Series: ICMS
Forecast Series: ICMSSM

Parameters:	Alpha	0.4200
	Beta	0.0000
	Gamma	0.0000
Sum of Squared Residuals		9.26E+10
Root Mean Squared Error		27774.03

End of Period Levels:	Mean	566280.9
	Trend	3600.253
	Seasonals: 2009M01	24467.52
	2009M02	-4260.936
	2009M03	-16082.79
	2009M04	-1105.742
	2009M05	-20922.50
	2009M06	-3818.148
	2009M07	-6959.302
	2009M08	-8003.755
	2009M09	-4768.108
	2009M10	-3518.661
	2009M11	10134.79
	2009M12	34837.63

Holt-Winters Sazonal Multiplicativo

Date: 02/14/11 Time: 10:10
Sample: 2000M01 2009M12
Included observations: 120
Method: Holt-Winters Multiplicative Seasonal
Original Series: ICMS
Forecast Series: ICMSSM

Parameters:	Alpha	0.4000
	Beta	0.0000
	Gamma	0.0000
Sum of Squared Residuals		9.06E+10
Root Mean Squared Error		27483.63

End of Period Levels:	Mean	562837.8
	Trend	3600.253
	Seasonals: 2009M01	1.086419
	2009M02	0.990361
	2009M03	0.991386
	2009M04	0.991234
	2009M05	0.937875
	2009M06	0.993654
	2009M07	0.973435
	2009M08	0.974471
	2009M09	0.977868
	2009M10	0.978658
	2009M11	1.023066
	2009M12	1.081573

8.3 Diagnóstico para o modelo Box-Jenkins: c ar(1) ar(2)

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.263251	Probability	0.952603
Obs*R-squared	1.703431	Probability	0.944856

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 03/22/11 Time: 22:23
Presample missing value lagged residuals set to zero.


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-4.10E-05	0.004232	-0.009689	0.9923
AR(1)	-0.095805	0.185743	-0.513034	0.6091
AR(2)	0.028193	0.187127	0.150660	0.8806
RESID(-1)	0.089226	0.214095	0.416759	0.6778
RESID(-2)	-0.150374	0.203550	-0.738755	0.4619
RESID(-3)	-0.063337	0.149150	-0.424649	0.6721
RESID(-4)	0.057066	0.110798	0.515042	0.6077
RESID(-5)	-0.023367	0.111357	-0.209834	0.8343
RESID(-6)	0.000976	0.108701	0.008980	0.9929
R-squared	0.016700	Mean dependent var	9.93E-15	
Adjusted R-squared	-0.067885	S.D. dependent var	0.077653	
S.E. of regression	0.080246	Akaike info criterion	-2.123355	
Sum squared resid	0.598859	Schwarz criterion	-1.891739	
Log likelihood	117.2911	F-statistic	0.197438	
Durbin-Watson stat	1.974038	Prob(F-statistic)	0.990605	

ARCH Test:

F-statistic	0.399249	Probability	0.877700
Obs*R-squared	2.516179	Probability	0.866653

Test Equation:
Dependent Variable: RESID*2
Method: Least Squares
Date: 03/22/11 Time: 22:24
Sample (adjusted): 2002M01 2009M12
Included observations: 96 after adjustments
White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.005646	0.001322	4.269860	0.0000
RESID*2(-1)	0.105277	0.127233	0.827430	0.4102
RESID*2(-2)	-0.009886	0.064400	-0.153503	0.8783
RESID*2(-3)	0.086920	0.132722	0.654899	0.5142
RESID*2(-4)	-0.086199	0.069069	-1.248006	0.2153
RESID*2(-5)	0.048086	0.064685	0.743391	0.4592
RESID*2(-6)	-0.062339	0.055624	-1.120713	0.2654
R-squared	0.026210	Mean dependent var	0.006133	
Adjusted R-squared	-0.039439	S.D. dependent var	0.010254	
S.E. of regression	0.010454	Akaike info criterion	-6.213499	
Sum squared resid	0.009727	Schwarz criterion	-6.026516	
Log likelihood	305.2480	F-statistic	0.399249	
Durbin-Watson stat	1.951553	Prob(F-statistic)	0.877700	



8.4 Diagnóstico para o modelo com Intervenção: c deg ar(1) ar(2) ma(3) ma(14)

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.265397	Probability	0.951621
Obs*R-squared	3.779147	Probability	0.706534

Test Equation:
Dependent Variable: RESID
Method: Least Squares
Date: 03/22/11 Time: 21:57
Presample missing value lagged residuals set to zero.


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.001192	0.004280	-0.278616	0.7812
DEG	0.001095	0.007783	0.140701	0.8884
AR(1)	0.040679	0.178955	0.227313	0.8207
AR(2)	0.015482	0.158193	0.097867	0.9223
MA(3)	-0.049310	0.072665	-0.678583	0.4991
MA(14)	-0.049463	0.072701	-0.680362	0.4980
RESID(-1)	0.002450	0.201902	0.012134	0.9903
RESID(-2)	0.059054	0.195494	0.302077	0.7633
RESID(-3)	0.075560	0.183242	0.412350	0.6811
RESID(-4)	0.067192	0.122155	0.550060	0.5836
RESID(-5)	-0.021154	0.122172	-0.173150	0.8629
RESID(-6)	-0.058514	0.124578	-0.469699	0.6397
R-squared	0.037050	Mean dependent var	-0.001324	
Adjusted R-squared	-0.080643	S.D. dependent var	0.070422	
S.E. of regression	0.073207	Akaike info criterion	-2.280925	
Sum squared resid	0.482332	Schwarz criterion	-1.972105	
Log likelihood	128.3272	F-statistic	0.314804	
Durbin-Watson stat	1.958473	Prob(F-statistic)	0.980956	

ARCH Test:

F-statistic	0.500605	Probability	0.806361
Obs*R-squared	3.134099	Probability	0.791838

Test Equation:
Dependent Variable: RESID*2
Method: Least Squares
Date: 03/22/11 Time: 21:53
Sample (adjusted): 2002M01 2009M12
Included observations: 96 after adjustments
White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.005453	0.001151	4.735897	0.0000
RESID*2(-1)	0.050398	0.060504	0.832964	0.4071
RESID*2(-2)	-0.076934	0.050278	-1.530162	0.1295
RESID*2(-3)	0.001732	0.078944	0.021938	0.9825
RESID*2(-4)	0.073798	0.063215	1.167404	0.2462
RESID*2(-5)	0.015908	0.068497	0.232242	0.8169
RESID*2(-6)	-0.130694	0.067350	-1.940511	0.0555
R-squared	0.032647	Mean dependent var	0.005154	
Adjusted R-squared	-0.032568	S.D. dependent var	0.008696	
S.E. of regression	0.008836	Akaike info criterion	-6.549789	
Sum squared resid	0.006949	Schwarz criterion	-6.362806	
Log likelihood	321.3899	F-statistic	0.500605	
Durbin-Watson stat	1.937096	Prob(F-statistic)	0.806361	




8.5 Diagnóstico para o modelo Econométrico

Correlogram of Residuals					
Date: 03/24/11 Time: 00:02 Sample: 2001M10 2009M12 Included observations: 99					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1		-0.086	-0.086	0.7552	0.385
2		-0.020	-0.027	0.7952	0.672
3		-0.092	-0.096	1.6692	0.644
4		0.240	0.227	7.7378	0.102
5		-0.086	-0.058	8.5192	0.130
6		0.064	0.064	8.9658	0.176
7		0.007	0.053	8.9713	0.255
8		0.116	0.064	10.460	0.234
9		-0.100	-0.049	11.576	0.238
10		-0.062	-0.101	12.015	0.284
11		0.058	0.057	12.397	0.335
12		0.005	-0.050	12.400	0.414

Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	0.824658	Probability	0.483694	
Obs*R-squared	0.523181	Probability	0.913770	
Test Equation:				
Dependent Variable: RESID				
Method: Least Squares				
Date: 03/22/11 Time: 22:39				
Presample missing value lagged residuals set to zero.				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLOG(ICMS(-1))	0.264132	0.228806	1.154397	0.2514
DLOG(ICMS(-2))	-0.116418	0.232782	-0.500114	0.6182
DLVIMPF(-1)	0.028815	0.040244	0.716021	0.4759
DLVABFF	0.002688	0.071166	0.037765	0.9700
DLVABFF(-1)	-0.074593	0.097088	-0.768304	0.4443
MCEF(-2)	0.222916	0.274015	0.813518	0.4181
MCEF(-3)	-0.113114	0.256633	-0.440764	0.6605
RESID(-1)	-0.318908	0.248693	-1.282334	0.2031
RESID(-2)	0.074015	0.196081	0.377470	0.7067
RESID(-3)	-0.112205	0.152584	-0.735365	0.4641
R-squared	0.005285	Mean dependent var	0.009041	
Adjusted R-squared	-0.095305	S.D. dependent var	0.060759	
S.E. of regression	0.063588	Akaike info criterion	-2.577234	
Sum squared resid	0.359870	Schwarz criterion	-2.315101	
Log likelihood	137.5731	Durbin-Watson stat	1.950533	

Ramsey RESET Test:				
F-statistic	0.354566	Probability	0.702453	
Log likelihood ratio	0.776988	Probability	0.678077	
Test Equation:				
Dependent Variable: DLOG(ICMS)				
Method: Least Squares				
Date: 03/22/11 Time: 22:42				
Sample: 2001M10 2009M12				
Included observations: 99				
White Heteroskedasticity-Consistent Standard Errors & Covariance				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLOG(ICMS(-1))	-0.778188	0.183310	-4.245202	0.0001
DLOG(ICMS(-2))	0.418179	0.192555	2.171732	0.0325
DLVIMPF(-1)	0.196469	0.048023	4.091153	0.0001
DLVABFF	0.306921	0.074972	4.093818	0.0001
DLVABFF(-1)	0.391021	0.079520	4.917281	0.0000
MCEF(-2)	-0.930734	0.221156	-4.208486	0.0001
MCEF(-3)	0.675299	0.204301	3.305407	0.0014
FITTED^2	0.389023	0.809280	0.480702	0.6319
FITTED^3	-0.24675	11.46954	-0.893388	0.3740
R-squared	0.548439	Mean dependent var	0.011452	
Adjusted R-squared	0.506301	S.D. dependent var	0.091065	
S.E. of regression	0.063856	Akaike info criterion	-2.577866	
Sum squared resid	0.366982	Schwarz criterion	-2.341946	
Log likelihood	136.6044	Durbin-Watson stat	2.117774	

White Heteroskedasticity Test:				
F-statistic	1.513612	Probability	0.123936	
Obs*R-squared	19.94348	Probability	0.131933	
Test Equation:				
Dependent Variable: RESID*2				
Method: Least Squares				
Date: 03/22/11 Time: 22:40				
Sample: 2001M10 2009M12				
Included observations: 99				
White Heteroskedasticity-Consistent Standard Errors & Covariance				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.003989	0.001343	2.970374	0.0039
DLOG(ICMS(-1))	-0.014737	0.012599	-1.169688	0.2454
(DLOG(ICMS(-1)))^2	0.034276	0.081961	0.418199	0.6769
DLOG(ICMS(-2))	-0.048753	0.030284	-1.609884	0.1112
(DLOG(ICMS(-2)))^2	0.052001	0.070488	0.737740	0.4627
DLVIMPF(-1)	-0.000170	0.002786	-0.061137	0.9514
DLVIMPF(-1)^2	-0.020387	0.10839	-1.880948	0.0634
DLVABFF	0.012274	0.011925	1.029252	0.3063
DLVABFF^2	-0.041631	0.042260	-0.985105	0.3274
DLVABFF(-1)	0.005060	0.008528	0.593287	0.5546
DLVABFF(-1)^2	0.050577	0.046529	1.087020	0.2801
MCEF(-2)	0.014848	0.018436	0.805380	0.4229
MCEF(-2)^2	0.020981	0.062481	0.335801	0.7379
MCEF(-3)	-0.045461	0.026822	-1.694884	0.0938
MCEF(-3)^2	0.019870	0.053628	0.370517	0.7119
R-squared	0.201449	Mean dependent var	0.003736	
Adjusted R-squared	0.068358	S.D. dependent var	0.006153	
S.E. of regression	0.005939	Akaike info criterion	-7.275768	
Sum squared resid	0.002963	Schwarz criterion	-6.882568	
Log likelihood	375.1505	F-statistic	1.513612	
Durbin-Watson stat	1.744370	Prob(F-statistic)	0.123936	



8.6 Tabela contendo os valores de AIC, SIC, valor p do coeficiente do termo “deg” e o erro de previsão (EPAM) para os meses de set/2008 a mar/2009. Do modelo BJ com intervenção: $d(\log(\text{icms})) \ c \ deg \ ar(1) \ ar(2) \ ma(3) \ ma(14)$

MÊS DA INTERV. DEGRAU	AIC	SIC	PROB COEF DEG=0	EPAM DA PREVISÃO
SET/2008	-2,383866	-2,229456	0,0165	6,6975
OUT/2008	-2,374702	-2,220292	0,0220	6,6221
NOV/2008	-2,365089	-2,210679	0,0386	6,7169
DEZ/2008	-2,362952	-2,208542	0,0505	6,7716
JAN/2009	-2,357931	-2,203520	0,0808	6,9910
FEV/2009	-2,342682	-2,188272	0,1648	7,2736
MAR/2009	-2,332470	-2,178060	0,3438	7,4683

Fonte: Software EViews

8.7 Modelo ARIMA para DLVIMP

Dependent Variable: DLOG(VIMP)
Method: Least Squares
Date: 11/11/10 Time: 10:50
Sample: 2001M07 2009M12
Included observations: 102
Convergence achieved after 9 iterations
White Heteroskedasticity-Consistent Standard Errors & Covariance
Backcast: 2001M05 2001M06

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.614887	0.111789	-5.500439	0.0000
MA(2)	0.352973	0.099285	3.555139	0.0006
R-squared	0.334839	Mean dependent var	0.008701	
Adjusted R-squared	0.328188	S.D. dependent var	0.189700	
S.E. of regression	0.155486	Akaike info criterion	-0.865108	
Sum squared resid	2.417592	Schwarz criterion	-0.813638	
Log likelihood	46.12051	Durbin-Watson stat	1.999879	
Inverted MA Roots	.31+.51i	.31-.51i		

Correlogram of Residuals Squared

Date: 03/23/11 Time: 23:53
Sample: 2001M07 2009M12
Included observations: 102

Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.202	0.202	4.2966		
2	-0.010	-0.053	4.3064		
3	-0.001	0.012	4.3066	0.038	
4	0.066	0.066	4.7716	0.092	
5	-0.058	-0.090	5.1430	0.162	
6	0.052	0.092	5.4386	0.245	
7	0.026	-0.009	5.5124	0.357	
8	-0.063	-0.075	5.9666	0.427	
9	-0.066	-0.023	6.4609	0.487	
10	-0.072	-0.079	7.0621	0.530	
11	-0.062	-0.028	7.5151	0.584	
12	-0.058	-0.037	7.9108	0.638	

8.8 Modelo ARIMA para DLIVABF

Dependent Variable: DLOG(IVABF)
Method: Least Squares
Date: 11/11/10 Time: 10:51
Sample: 2001M07 2009M12
Included observations: 102
Convergence achieved after 12 iterations
White Heteroskedasticity-Consistent Standard Errors & Covariance
Backcast: 2000M07 2001M06

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.386007	0.087940	-4.389456	0.0000
AR(3)	0.340877	0.086853	3.924742	0.0002
SAR(12)	0.985154	0.013903	70.85856	0.0000
MA(12)	-0.888227	0.028406	-31.26853	0.0000
R-squared	0.885108	Mean dependent var	0.007582	
Adjusted R-squared	0.881591	S.D. dependent var	0.108986	
S.E. of regression	0.037503	Akaike info criterion	-3.690372	
Sum squared resid	0.137834	Schwarz criterion	-3.587432	
Log likelihood	192.2090	Durbin-Watson stat	1.992263	
Inverted AR Roots	1.00	.86-.50i	.86+.50i	.59
	.50+.86i	.50-.86i	.00+1.00i	-.00-1.00i
	-.49+.58i	-.49-.58i	-.50+.86i	-.50-.86i
	-.86-.50i	-.86+.50i	-1.00	
Inverted MA Roots	.99	.86-.50i	.86+.50i	.50-.86i
	.50+.86i	.00+.99i	-.00-.99i	-.50+.86i
	-.50-.86i	-.86+.50i	-.86-.50i	-.99

Correlogram of Residuals Squared						
Date: 03/23/11 Time: 23:57 Sample: 2001M07 2009M12 Included observations: 102 Q-statistic probabilities adjusted for 4 ARMA term(s)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1 0.011	0.011	0.0127		
		2 -0.061	-0.061	0.4010		
		3 -0.009	-0.007	0.4088		
		4 -0.132	-0.136	2.3081		
		5 -0.003	-0.001	2.3089	0.129	
		6 -0.122	-0.143	3.9531	0.139	
		7 0.089	0.093	4.8280	0.185	
		8 0.047	0.006	5.0797	0.279	
		9 -0.068	-0.058	5.6062	0.346	
		10 -0.042	-0.075	5.8122	0.445	
		11 0.116	0.142	7.3843	0.390	
		12 -0.055	-0.087	7.7392	0.459	

8.9 Modelo ARIMA para MCE

Dependent Variable: MCE
Method: Least Squares
Date: 11/09/10 Time: 12:29
Sample (adjusted): 2001M10 2009M12
Included observations: 99 after adjustments
Convergence achieved after 2 iterations
White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.236160	0.103500	2.281739	0.0247
AR(2)	0.202568	0.093513	2.166188	0.0328
AR(3)	0.247841	0.111884	2.215162	0.0291
R-squared	0.282590	Mean dependent var	0.000617	
Adjusted R-squared	0.267644	S.D. dependent var	0.089392	
S.E. of regression	0.076500	Akaike info criterion	-2.273214	
Sum squared resid	0.561818	Schwarz criterion	-2.194574	
Log likelihood	115.5241	Durbin-Watson stat	1.971154	
Inverted AR Roots	.83	-.30-.46i	-.30+.46i	

Correlogram of Residuals Squared						
Date: 03/23/11 Time: 23:59 Sample: 2001M10 2009M12 Included observations: 99 Q-statistic probabilities adjusted for 3 ARMA term(s)						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1 0.018	0.018	0.0322		
		2 0.002	0.001	0.0325		
		3 0.171	0.171	3.0838		
		4 0.032	0.027	3.1910	0.074	
		5 -0.037	-0.039	3.3374	0.188	
		6 -0.034	-0.064	3.4633	0.326	
		7 -0.002	-0.011	3.4639	0.483	
		8 0.048	0.063	3.7156	0.591	
		9 -0.005	0.014	3.7186	0.715	
		10 0.099	0.106	4.8231	0.682	
		11 -0.034	-0.063	4.9568	0.762	
		12 0.070	0.066	5.5263	0.786	

8.10 Desvios padrão amostrais para o período de jul/2001 a dez/2009, para o cálculo do coeficiente beta.

$$DP_{LICMS} = 0,395077$$

$$DP_{LVIMP} = 0,525156$$

$$DP_{LIVABF} = 0,233297$$

$$DP_{LINEF} = 0,144565$$