

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO
PUC-SP

Emerson Oliveira de Queirós

**Modelo de previsão para receita tributária estadual: aplicação da
metodologia Box-Jenkins**

MESTRADO EM ECONOMIA POLÍTICA

SÃO PAULO
2012

Emerson Oliveira de Queirós

Modelo de previsão para receita tributária estadual: aplicação da metodologia Box-Jenkins

MESTRADO EM ECONOMIA POLÍTICA

Dissertação apresentada à Banca Examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de MESTRE em Economia Política, sob a orientação do Prof. Dr. César Roberto Leite da Silva.

SÃO PAULO

2012

Emerson Oliveira de Queirós

**Modelo de previsão para a receita tributária estadual: aplicação da
metodologia Box-Jenkins**

Dissertação apresentada à Banca Examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de MESTRE em Economia Política, sob orientação do Prof. Dr. César Roberto Leite da Silva.

Aprovado em _____ de _____ de 2012.

Banca Examinadora

*Dedico este trabalho à minha mãe, **dona Elizete**, in memoriam, por ter doado sua vida em prol de muitas pessoas. Cumpriu seu papel aqui na Terra de modo singular. Obrigado mãe, por tudo, muito obrigado.*

AGRADECIMENTOS

Em primeiro lugar, agradeço a **Deus** – força suprema que nos induz a trilhar o caminho da vitória. Ao meu pai, seu **João Emmanuel**, por ter sido fundamental no processo de minha formação intelectual e humana; aos meus irmãos, **João, Everton, Solange, Patrícia, Elton** e **William**; às minhas primas, **Sheila** e **Ana Lúcia**, pelo apoio nos momentos difíceis. Amo todos vocês. À minha esposa, **Alessandra Santana**, pelo companheirismo e ajuda nos momentos críticos.

Ao meu orientador, o **Prof. Dr. César Roberto Leite da Silva**, pelos ensinamentos, pela ajuda e pela paciência durante a jornada. Agradeço também à Coordenadora do Programa, **a Prof^a. Dr^a. Regina Maria A. Fonseca Gadelha**. *Parabéns pelo* belo trabalho desenvolvido a favor do Programa de Economia Política da PUC-SP. À **Sonia Santos Petrohilos** dedico especial agradecimento por todo o suporte oferecido durante o mestrado. Agradeço muito aos Professores da Banca de Qualificação: **Prof. Dr. Vladimir Cipriano Camillo** e o **Prof. Dr. Fernando Ribeiro Leite Neto**.

Aos meus camaradas: Glauco Freire; Lincoln Lima; Marcelo Figueiredo e Lucas Godeiro. Foram inesquecíveis os momentos que tive com cada um desses incríveis seres humanos. Boa sorte e saúde a todos vocês, meus camaradas! Agradeço também à Capes pela bolsa de estudos

Quando se trata de liberdade, o conservador deveria ou calar ou encontrar algo de útil para dizer. Eu penso que há algo de útil a ser dito, e é o que está aqui.

G. J. Stigler

RESUMO

O presente trabalho objetiva aplicar a metodologia Box-Jenkins, conhecida também como metodologia ARIMA, a fim de construir um modelo de previsão de curto prazo para o imposto estadual (ICMS). Trata-se de um imposto de grande peso relativo nas receitas dos estados no Brasil. Portanto, antecipar precisamente o volume de recursos advindos da principal fonte de receita dos estados no Brasil, além de ser uma imposição legal, pode ser também crucial na gestão financeira dos Estados. Os resultados indicaram que a metodologia Box-Jenkins pode ser uma ferramenta útil se a intenção for construir um modelo de previsão de curto prazo para o imposto com as características do ICMS.

Palavras-chave: Previsão de Receita Tributária. ICMS. Metodologia Box-Jenkins. ARIMA.

ABSTRACT

The goal of the present work is to use the Box-Jenkins methodology, also known as ARIMA methodology, to build a short-term model of prediction for the state tax (ICMS) revenue. This tax is the most important source of income for the states in Brazil. Therefore, to predict precisely the volume of resources to be collected, other than being a legal requirement, may also be crucial for the financial management of the States. The results achieved indicate that the Box-Jenkins methodology can be a useful tool to forecast the short-term tax revenue from taxes with the characteristics of the ICMS (Value Add Tax).

Keywords: Tax revenue forecasting. Value added tax (ICMS). Box-Jenkins methodology. ARIMA.

LISTA DE TABELAS

Tabela 1 – Os 10 maiores tributos recolhidos no Brasil em 2010	23
Tabela 2 – Receita Tributária da União, Estados e Municípios no período de 2006 a 2010, em milhões de reais.....	23
Tabela 3 – Participação da arrecadação tributária como percentual do PIB no período de 2006-2010	24
Tabela 4 – Receita estadual (corrente e tributária), período 2005-2010, em milhões de reais.....	24
Tabela 5 – Participação relativa do ICMS na receita (corrente e tributária) estadual, período 2005-2010, em percentual.....	25
Tabela 6 – Participação relativa (% total) dos principais tributos na arrecadação tributária dos Estados no Brasil, período 2006-2010.....	25
Tabela 7 – Arrecadação do ICMS (participação relativa) de cada UF dentro da região em 2010.....	69
Tabela 8 – Resultados dos testes de raiz unitária para o modelo com constante ...	72
Tabela 9 – Resultados dos testes de raiz unitária para o modelo com tendência e constante	72

LISTA DE ILUSTRAÇÕES

Quadro 1 – Composição do ICMS.....	20
Quadro 2 – Evolução do imposto sobre o consumo no Brasil	21
Quadro 3 – Legislação estadual do ICMS	22
Quadro 4 – Problemas comuns nas séries de tempo.....	53
Quadro 5 – Atributos da FAC e da FACP	58
Quadro 6 – Atributos da FAC e FACP dos processos sazonais SARMA (P,Q)	59
Quadro 7 – A Série é (S) ou não (N) estacionária.....	74
Quadro 8 – Modelos de previsão estimados para o ICMS dos estados.....	75

LISTA DE SIGLAS E ABREVIATURAS

ADF TEST	<i>Augmented Dickey-Fuller Test</i>
AIC	Critério de Informação de Akaike
AR	<i>Autogressive</i> ou autorregressivo
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
BIC	Critério Bayesiano de Schwarz
CBO	<i>Congressional Budget Office</i>
COFINS	Contribuição para o Financiamento da Seguridade Social
DOU	Diário Oficial da União
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
FGTS	Fundo de Garantia do Tempo de Serviço
IBGE	Instituto Brasileiro de Geografia e Estatística
ICM	Imposto sobre Circulação de Mercadorias
ICMS	Imposto sobre circulação de mercadorias e prestação de serviços de comunicação e de transportes
IPEA	Instituto de Pesquisa em Economia Aplicada
IPI	Imposto sobre Produtos Industrializados
IPVA	Imposto sobre a Propriedade de Veículos Automotores
IR	Imposto de Renda
IRPJ	Imposto de Renda das Pessoas Jurídicas
ITCMD	Imposto sobre a Transmissão Causa Mortis e Doação
IVC	Imposto sobre Vendas e Consignações
IVM	Imposto sobre Vendas Mercantis
KPSS TEST	<i>Kwiatkowski–Phillips–Schmidt–Shin test</i>
LOA	Lei do Orçamento Anual
LRF	Lei de Responsabilidade Fiscal
LSE	<i>London School of Economics</i>
MA	<i>Movie Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentual Error</i>
MSE	<i>Mean Square Error</i>

PIB	Produto Interno Bruto
PIS	Programa de Integração Social
PP TEST	<i>Phillips-Perron Test</i>
QH	Critério de Informação de Hannan-Quinn
RFB	Receita Federal do Brasil
RNA	Redes Neurais Artificiais
SAR	Sazonal Autorregressivo
SARIMA	Sazonal Autorregressivo Integrado Média Móvel
SEFAZ-AM	Secretaria de Estado da Fazenda do Amazonas
SEFAZ-BA	Secretaria de Estado da Fazenda da Bahia
SEFAZ-GO	Secretaria da Fazenda do Estado de Goiás
SEFAZ-RS	Secretaria da Fazenda do Estado do Rio Grande do Sul
SEFAZ-SP	Secretaria da Fazenda do Estado de São Paulo
SMA	Sazonal Média Móvel
SRFB	Secretaria da Receita Federal do Brasil
SUFRAMA	Superintendência da Zona Franca de Manaus

SUMÁRIO

INTRODUÇÃO	15
1 O ICMS, A LEI DE RESPONSABILIDADE FISCAL E A PREVISÃO DA ARRECADAÇÃO TRIBUTÁRIA	17
1.1 CONSIDERAÇÕES INICIAIS.....	17
1.2 ICMS: histórico.....	18
1.3 ICMS: arcabouço legal.....	21
1.4 ICMS: o peso na economia brasileira	22
1.5 A LEI DE RESPONSABILIDADE FISCAL E A PREVISÃO DA ARRECADAÇÃO RECEITA TRIBUTÁRIA	26
1.5.1 A previsão.....	27
1.5.2 A previsão de tributos: revisão da literatura	29
2 PRINCÍPIOS ELEMENTARES DA ANÁLISE DE SÉRIES TEMPORAIS LINEARES.....	34
2.1 CONSIDERAÇÕES INICIAIS.....	34
2.2 ANÁLISE DE SÉRIES DE TEMPO LINEARES	35
2.3 PROCESSOS ESTOCÁSTICOS	36
2.4 PROCESSO ESTOCÁSTICO ESTACIONÁRIO	37
2.5 RUÍDO BRANCO	39
2.6 A FUNÇÃO DE AUTOCORRELAÇÃO E AUTOCORRELAÇÃO PARCIAL	39
2.7 PROCESSO ESTOCÁSTICO AUTORREGRESSIVO	42
2.8 PROCESSO ESTOCÁSTICO MÉDIA MÓVEL	44
2.9 PROCESSO AUTORREGRESSIVO E DE MÉDIA MÓVEL	46
2.10 PROCESSOS SAZONAIS	47
3 A METODOLOGIA BOX-JENKINS	49
3.1 CONSIDERAÇÕES INICIAIS.....	49
3.2 ITERAÇÃO E PARCIMÔNIA.....	50
3.3 PREPARANDO OS DADOS	52
3.4 TESTES DE RAIZ UNITÁRIA	53

3.5	IDENTIFICAÇÃO	57
3.5.1	Análise do correlograma	57
3.5.2	Critério de informação	59
3.6	ESTIMAÇÃO	61
3.7	VALIDAÇÃO	63
3.8	PREVISÃO	66
4	APLICAÇÃO DA METODOLOGIA BOX-JENKINS	68
4.1	CONSIDERAÇÕES INICIAIS.....	68
4.2	DADOS DA PESQUISA E METODOLOGIA.....	69
4.3	ANÁLISE DE INTERVENÇÃO, FUNÇÃO DE TRANSFERÊNCIA E A DETECÇÃO DE <i>OUTLIERS</i>	70
4.4	RESULTADOS DOS TESTES DE RAIZ UNITÁRIA	71
4.5	MODELOS ESTIMADOS E O RESULTADO DA PREVISÃO.....	74
	CONSIDERAÇÕES FINAIS	78
	REFERÊNCIAS.....	81
	APÊNDICES	87
	ANEXOS	97

INTRODUÇÃO

No Brasil, são recorrentes as críticas ao modo como é aplicado o dinheiro público pelos gestores. Os recursos arrecadados pela União, estados, Distrito Federal e municípios podem – e devem – ser aplicados de maneira parcimoniosa, de modo a garantir condições dignas à população, mormente fração mais carente. Em um país como o Brasil, no qual fração significativa da população ainda carece de serviços essenciais que demandam vultosos recursos, *vis-à-vis* volume arrecadado, a estratégia e a gestão orçamentária tornam-se relevantes.

O processo da gestão orçamentária no Brasil inicia-se a partir da elaboração do documento orçamentário, materializado na Lei do Orçamento Anual (LOA). Nesta lei, resumidamente, encontram-se os elementos norteadores para o setor público no que concerne à entrada e à saída de recursos públicos. Ou seja, na LOA consta a política de gastos e a estimativa de receita do setor público para um determinado exercício financeiro.

Outro instrumento balizador dos gastos no Brasil é a Lei de Responsabilidade Fiscal (LRF). Esta lei, entre outros, abarca uma série de diretrizes e de limitações que diz respeito aos gastos e despesas do setor público, englobando todas as esferas de governo no Brasil.

Uma questão relevante da LRF diz respeito à obrigação dos entes em realizar a previsão de todos os tributos arrecadados. Também é citado na lei que os recursos arrecadados previstos deverão ter sua memória de cálculo divulgada.

O tema central deste trabalho se relaciona com os dois temas anteriormente abordados do seguinte modo. Primeiramente, ele visa prever. Mais especificamente, relaciona-se com o modo de procedimento adotado para realizar a previsão do tributo estadual ICMS.

Deste modo, o trabalho trata de dois aspectos importantes. Por um lado trata-se do principal tributo do país; por outro lado, aborda uma questão de cunho legal. A importância do ICMS para os estados e o caráter obrigatório em prevê-lo são o pano de fundo que deu origem a esta pesquisa.

Há uma ampla variedade de métodos de previsão que podem ser adotados para prever os tributos ou qualquer outra variável econômica. Chatfield (2000) classifica os métodos de previsão em três tipos: os métodos por julgamentos, nos

quais se utiliza apenas da *expertise* ou experiência do previsor; os métodos multivariados, em que se utiliza mais do que uma série de dados e também se conhece *a priori* o relacionamento entre as variáveis utilizadas; e os métodos univariados, que adotam apenas uma série de tempo e não prescindem de nenhuma teoria para formular um modelo de previsão. O escopo deste trabalho relaciona-se com este último método de previsão.

O objetivo do trabalho, portanto, é aplicar a metodologia das séries temporais lineares univariadas para prever a arrecadação mensal do ICMS para cinco estados brasileiros. Especificamente, adota-se a metodologia Box-Jenkins, também conhecida como metodologia ARIMA, para construir um modelo de previsão de curto prazo para o ICMS.

É importante deixar claro, outrossim, que o trabalho não pretende comparar modelos de previsão. Visa somente aplicar uma metodologia específica que pode ser adotada para construir um modelo formal para prever um imposto com as características do ICMS. Não se pretende, também, analisar profundamente os resultados obtidos na modelagem. Essa é uma questão que envolve o conhecimento da estrutura econômica e tributária de cada estado e foge do escopo do trabalho.

O trabalho está organizado em quatro capítulos e considerações finais. No primeiro capítulo abordam-se questões relacionadas ao imposto estadual ICMS, à LRF e à previsão. A ideia central do primeiro capítulo, portanto, é apresentar ao leitor as características principais da variável a ser prevista, o ICMS, mostrar o caráter compulsório da previsão e, por fim, fazer uma resenha acerca da previsão de tributos.

O segundo e terceiro capítulos tratam de questões relacionadas aos fundamentos básicos da análise de séries temporais e da metodologia Box-Jenkins, respectivamente. Pretende-se estudar a metodologia selecionada para prever o tributo estadual ICMS.

No quarto e último capítulo, aplica-se a metodologia Box-Jenkins para construir um modelo de previsão de curto prazo do ICMS estadual para cinco estados brasileiros, a saber: Bahia, Amazonas, Goiás, Rio Grande do Sul e São Paulo.

1 O ICMS, A LEI DE RESPONSABILIDADE FISCAL E A PREVISÃO DA ARRECADAÇÃO TRIBUTÁRIA

1.1 CONSIDERAÇÕES INICIAIS

O ICMS lidera o *ranking* da arrecadação de tributos no Brasil, independentemente da esfera de governo. Por isso, pode-se afirmar que esse tributo é um dos mais relevantes no país. A arrecadação desse imposto superou a marca de R\$ 250 bilhões em 2010 (ver tabela 1).

Diante do volume de recursos arrecadados anualmente pelos governos estaduais e considerando também o peso que esse tributo tem na composição orçamentária dos estados e do Distrito Federal, é imprescindível que os seus custodiantes empreendam esforços no sentido de gerir e controlar essa fonte de recursos.

Nesse contexto, uma tarefa importante no contexto da “gestão fiscal responsável” é a elaboração da previsão orçamentária. Os gestores responsáveis pela administração dos tributos e, particularmente, os envolvidos diretamente com a gestão da arrecadação devem ter a responsabilidade de elaborar cuidadosamente a previsão da arrecadação dos tributos sob sua custódia.

Foi com essa ideia que, no ano 2000, surgiu no ordenamento jurídico brasileiro a figura da Lei de Responsabilidade Fiscal (LRF), cuja missão, entre outras, era a incutir a ideia de “gestão fiscal responsável” aos gestores de recursos públicos no Brasil.

Entre outras questões importantes, a LRF impunha aos entes federados uma série de limitações em matéria orçamentária. Cita-se, por exemplo, a obrigatoriedade dos entes federados na elaboração da previsão de todos os recursos arrecadados, sob pena de o gestor público ser punido caso não observe os ditames desta lei.

Em linhas gerais, a ideia central da LRF era de que não se poderia gastar mais do que se arrecadava. Nesse sentido, essa lei sinalizava que a previsão poderia contribuir para que entes não incorressem em orçamentos fiscais irrealizáveis.

Deste modo, conforme delineia a LRF, a previsão pode ser encarada como elemento essencial para uma gestão fiscal responsável. Sob outro enfoque, o Estado acaba influenciando também para que o assunto previsão fizesse parte da agenda de trabalho e fosse tratado de forma mais responsável. Além disso, com a criação da LRF, o número de trabalhos acadêmicos na área de previsão de tributos aumentou de modo expressivo no Brasil.

Sendo assim, a proposta deste primeiro capítulo é tripla. Primeiramente, visa apresentar as principais características do principal imposto estadual no Brasil, o ICMS. Em segundo lugar, aborda-se a questão da previsão de tributos. Por fim, o capítulo visa também revisar a literatura sobre a previsão de tributos no Brasil.

1.2 ICMS: histórico

De uma alguma forma, pode-se afirmar que a história do ICMS está vinculada ao antigo Imposto sobre Vendas Mercantis (IVM), apesar de o atual ICMS ter características que não se alinham com o antigo imposto sobre vendas mercantis. Não obstante, comumente se faz essa associação para traçar o panorama histórico do ICMS.

O IVM foi instituído pela Lei n.º 4.625, de 31 de dezembro de 1922. A competência legislativa e administrativa desse imposto pertencia ao Governo Central (IPEA, 1996). A sua principal característica era a sistemática de cobrança. A incidência do IVM ocorria de forma cumulativa e plurifásica.

Segundo Medeiros Neto (2001), os impostos cumulativos são aqueles que incidem em duas ou mais etapas na circulação econômica, sem que se permita abater o montante pago na etapa anterior nas operações subsequentes. Em outros termos, os impostos cumulativos são caracterizados por incidirem em todas as etapas do processo de produção e de circulação. Essa sistemática de cobrança é, por esse motivo, vulgarmente chamada de cobrança em “cascata” (CARDOSO, 2009).

A vigência do IVM pode ser considerada relativamente curta. Em 1934, em decorrência da nova Constituição Federal do país, extingue-se o imposto sobre vendas e é criado então o Imposto sobre Vendas e Consignações (IVC). A

competência desse novo imposto passa a ser estadual. Outra característica do IVC é que sua base de incidência é ampliada, passando a contemplar também as consignações. Destaca-se também que o IVC mantém o mesmo modo de cobrança de seu antecessor; ou seja, continua a onerar plurifasicamente e de forma cumulativa as operações sobre vendas e consignações.

O IVC somente foi abolido no ano de 1965 durante o Regime Militar, com a Emenda Constitucional n.º 18 daquele mesmo ano. Diferentemente da “Reforma Tributária” que deu origem ao imposto sobre vendas e consignações em 1934, as mudanças implementadas em 1965 aboliram a figura da cobrança cumulativa nas operações incidentes do IVC. Assim, em 1965, é criado o Imposto sobre Circulação de Mercadorias (ICM)¹.

Pode-se dizer, portanto, que a não cumulatividade é a principal característica do ICM.² Em linhas gerais, a ideia da sistemática de cobrança não cumulativa é abater o imposto já cobrado em etapa anterior nas operações subsequentes. Segundo Silveira (2008, p. 329), a lógica desse modo de cobrança não cumulativa é que se deve pagar “o imposto que incidir tão somente sobre o valor agregado em cada etapa da circulação da mercadoria, de tal modo que o resultado final seja idêntico à aplicação”.

Não obstante todas as mudanças ocorridas com o imposto sobre o consumo no Brasil no período 1922-1965, onde foi vista a figura de três diferentes tipos de impostos – IVM, IVC e o ICM –, caberia ainda mais uma alteração na estrutura tributária dos impostos sobre o consumo dos estados no Brasil. Por ocasião da promulgação da Constituição Federal no Brasil de 1998, extingue-se o ICM e em seu lugar surge o ICMS.

A característica do novo imposto criado continua a ser a cobrança não cumulativa. No entanto, o ICMS tem a base de incidência ampliada e passa a contemplar uma série de impostos (únicos e especiais) que eram anteriormente de competência da União.

Assim, a nomenclatura do novo imposto – ICMS –, apesar de se ter inserido apenas a letra “s” em sua sigla, além da inclusão dos serviços (comunicação e

¹O ICM passa a vigor somente no ano de 1967.

²Segundo Cardoso (2009, p. 20) a não cumulatividade no Brasil inicia-se com a Lei n. 3.520/58. Para o autor, aplicava-se a referida lei apenas para operações incidentes sobre o imposto sobre o consumo de competência do governo federal.

transporte), abarcou também uma série de outros tributos. O quadro 1 abaixo mostra a composição do ICMS a partir de 1988.

I C M S	Imposto		Sigla	Competência
	01	Imposto sobre Circulação de Mercadorias	ICM	Estadual
	02	Imposto Especial de Comunicação	IEC ^(a)	Federal
	03	Imposto Especial de Transporte	IET ^(a)	Federal
	04	Imposto Único sobre Minerais	IUM ^(b)	Federal
	05	Imposto Único de Energia Elétrica	IUEE ^(c)	Federal
	06	Imposto Único sobre Combustíveis	IUCL ^(d)	Federal

Quadro 1 – Composição do ICMS

Fonte: Elaborado pelo autor com base nas legislações consultadas.

Notas: a) IUCL foi criado pela Lei nº 04/1940 e pelo Decreto nº 22.615 de 1940; b) o IUM, pelo Decreto nº 92.295/1986; c) o IUEE foi instituído pela CF/1946 e pelo Decreto nº 2.308/1954.

Encerra-se, deste modo, o que pode ser considerado como o histórico do imposto sobre o consumo brasileiro no período republicano do Brasil. Atualmente, o ICMS é regulamentado pela Lei nº 87, de 16 de setembro de 1996, também conhecida como Lei Kandir, e está delineado no artigo 153, II, da Constituição Federal do Brasil de 1988.³

³Entre o período de tempo de sua criação, no ano de 1998, até a data de criação da lei Kandir, em 1996, o ICMS foi regulamentado, provisoriamente, pelo Convênio nº 66/88, que fixava normas provisórias para regulamentar o ICMS, publicado no Diário Oficial da União (DOU) em 16 de dezembro de 1988.

O quadro abaixo sintetiza a evolução do imposto do consumo no Brasil, retratando tudo aquilo que se disse nos parágrafos na seção.

TRIBUTO	SIGLA	COMPETÊNCIA	INCIDÊNCIA	NORMA
Imposto sobre Mercantis	IVM	Federal	Cumulativo	Lei nº 42.652/1922
Imposto sobre Vendas e Consignações	IVC	Estadual	Cumulativo	CF/1946
Imposto sobre Circulação de Mercadorias	ICM	Estadual	Não cumulativo	EC. nº 18/1965
Imposto sobre Circulação de Mercadorias e Serviços	ICMS	Estadual	Não cumulativo	CF/1988 e Lei nº 87/1996

Quadro 2 – Evolução do imposto sobre o consumo no Brasil
Fonte: Elaborado pelo autor com base no referencial teórico.

1.3 ICMS: arcabouço legal

Segundo a Constituição Federal de 1988 (BRASIL, 1988), o ICMS é definido como “imposto sobre operações sobre circulação de mercadorias e prestação de serviço de transporte interestadual e intermunicipal e de comunicação”. Insere-se no rol de tributos da competência dos estados e do Distrito Federal e está delineado no artigo 153 da referida Constituição, *in verbis*:

Art. 153: Compete aos Estados e ao Distrito Federal instituir impostos sobre:
I – (...) omissis

II – operações relativas à circulação de mercadorias e sobre prestações de serviços de transporte interestadual e intermunicipal e de comunicação (...).

Apesar de o ICMS ter sido instituído pela Constituição Federal de 1988, somente no ano de 1996 é que foi criada uma lei regulamentadora para o referido imposto. Trata-se da Lei nº 87, de 16 de setembro de 1996, conhecida também por Lei Kandir. É nesta lei que se encontram as regras gerais do ICMS que deverão ser observadas pelos estados e o Distrito Federal.

Outro aspecto digno de nota é que, apesar de os estados e o Distrito Federal obedecerem aos ditames da Constituição Federal de 1988 e da Lei Kandir no que diz respeito ao ICMS, cada um desses entes federados tem leis e regulamentos

próprios. O quadro abaixo apresenta algumas normas pertinentes ao ICMS para alguns estados brasileiros.

ESTADO	LEI APLICÁVEL AO ICMS ESTADUAL	
Amazonas	Lei nº 19/1997	Dec. nº 20.686/99
Bahia	Lei nº 7.014/1996	Dec. nº 6.284/1997
Goiás	Lei nº 11.651/1991	Dec. nº 4.852/1997
Rio Grande do Sul	Lei nº 8.820/1989	Dec. nº 37.699/1997
São Paulo	Lei nº 6.374/1997	Dec. nº 4.549/2000

Quadro 3 – Legislação estadual do ICMS⁴

Fonte: Elaborado pelo autor com base nas legislações citadas.

1.4 ICMS: o peso na economia brasileira

A participação relativa do ICMS na economia brasileira vem crescendo nos últimos anos. Em relação à receita corrente ou tributária estadual, o peso desse tributo na economia do país é elevado. Em 2010, a arrecadação desse imposto somou R\$ 256,8 bilhões.

As tabelas apresentadas abaixo evidenciam, a partir de diferentes indicadores, o peso desse tributo para a economia brasileira nos últimos cinco anos. Primeiramente, a tabela 1 apresenta o *ranking* nacional dos impostos no Brasil.

Conforme citado, o ICMS aparece no topo da tabela, com participação de 21,09% do total de tributos arrecadados em 2010. Vale ressaltar que o ICMS arrecadado em 2010 superou até mesmo o Imposto de Renda (IR) do governo federal que, em 2010, atingiu a cifra de R\$ 216,416 bilhões.

A carga tributária no Brasil, em 2010, de acordo com os dados divulgados pela Receita Federal do Brasil (RFB), foi de 33,56% do PIB nominal, reflexo de uma arrecadação tributária bruta de R\$ 1,233 trilhões e PIB nominal da ordem de R\$ 3,675 trilhões (RFB, 2011).

⁴A maioria das leis citadas sofreram alterações e/ou foram revogadas.

Tabela 1 – Os 10 maiores tributos recolhidos no Brasil em 2010

CLAS.	TIPO DE TRIBUTOS	TOTAL* (%)	PIB** (%)	VALOR (MILHÕES R\$)
1º	ICMS	21,09%	6,99%	256.837,91
2º	Imposto de renda	17,53%	5,81%	213.416,71
3º	Contribuição para a previdência social	17,41%	5,77%	211.968,53
4º	COFINS	11,43%	3,79%	139.174,35
5º	Contribuição para o FGTS	5,07%	1,68%	61.797,21
6º	Contribuição social para o lucro líquido	3,74%	1,24%	45.487,17
7º	Imposto sobre Produtos Industrializados (IPI)	3,06%	1,02%	37.305,31
8º	Contribuição para o PIS	2,49%	0,83%	30.337,50
9º	Imposto sobre Serviços	2,25%	0,75%	27.417,76
10º	Impostos sobre Operações Financeiras	2,18%	0,72%	26.537,59

Fonte: Adaptada da RFB (2011).

Nota: *Refere-se à participação percentual em relação à arrecadação tributária total no valor de R\$ 1,233 trilhões. **Em relação ao valor do PIB nominal registrado no ano de 2010, que foi da ordem de R\$ 3,675 trilhões, segundo metodologia do Instituto Brasileiro de Geografia e Estatística (IBGE).

As tabelas 2 e 3 mostram a divisão do “bolo orçamentário” entre as diferentes esferas de governo. Observa-se a expressiva participação da União que, em 2010, arrecadou mais de R\$ 862,275 bilhões em tributos.

Caso a comparação seja realizada em função da riqueza que se gera no país, comumente retratada pelo valor do Produto Interno Bruto (PIB), em 2010, a carga tributária no Brasil foi de 33,56% do PIB. A divisão desse percentual é mostrada na tabela 3.

Tabela 2 – Receita Tributária da União, Estados e Municípios no período de 2006 a 2010, em milhões de reais

Governo	Arrecadação Tributária Estadual anual (em milhões)				
	2006	2007	2008	2009	2010
União	553.099,16	637.073,50	724.880,39	737.037,69	862.275,64
Estados	203.423,01	224.971,32	262.949,16	270.046,37	311.197,30
Municípios	33.839,46	41.374,46	46.230,94	48.356,17	60.018,38
Total	790.361,63	903.419,28	1.034.060,49	1.055.440,23	1.233.491,32

Fonte: Receita Federal do Brasil (2011).

Tabela 3 – Participação da arrecadação tributária como percentual do PIB no período de 2006-2010

Governo	Arrecadação/PIB (em %)				
	2006	2007	2008	2009	2010
União	23,34%	23,94%	23,91%	23,14%	23,46%
Estados	8,59%	8,45%	8,67%	8,48%	8,47%
Municípios	1,43%	1,55%	1,52%	1,52%	1,63%
Total	33,36%	33,94%	34,10%	33,14%	33,56%

Fonte: Elaboração própria com base na Receita Federal do Brasil (2011).

No que diz respeito aos dados da receita pública dos estados, as tabelas 5 e 6 mostram a evolução da receita (corrente e tributária) para algumas unidades da federação. O destaque da tabela 5 é o valor da arrecadação tributária do estado de São Paulo relativamente aos demais estados mostrados na referida tabela.

Tabela 4 – Receita estadual (corrente e tributária), período 2005-2010, em milhões de reais

Receita Corrente						
UF/ANO	2005	2006	2007	2008	2009	2010
Goiás	8.095,5	8.692,8	10.164,4	12.135,4	12.564,8	14.728,1
Bahia	15.135,9	16.845,2	17.545,8	20.189,0	20.915,4	24.652,0
São Paulo	73.870,6	82.078,6	92.275,6	107.688,1	113.618,0	131.045,3
R. G. do Sul	17.925,1	19.273,3	20.588,8	24.659,5	26.157,9	30.796,3
Amazonas	5.606,3	6.137,5	7.036,7	8.567,7	8.302,4	10.066,1
Receita Tributária						
UF/ANO	2005	2006	2007	2008	2009	2010
Goiás	4.894,3	5.459,5	6.453,9	7.700,9	8.121,9	9.669,4
Bahia	7.650,0	8.618,8	9.458,1	10.886,6	10.840,4	12.877,0
São Paulo	57.066,1	63.419,9	71.539,0	85.749,0	89.345,6	103.211,8
R. G. do Sul	12.629,7	13.501,9	14.239,7	17.099,1	17.859,1	21.419,6
Amazonas	3.205,3	3.596,4	3.991,5	4.953,0	4.642,1	5.961,0
Receita do ICMS						
UF/ANO	2005	2006	2007	2008	2009	2010
Goiás	4.078,9	4.522,5	5.311,2	6.342,5	6.560,9	7.810,1
Bahia	6.877,1	7.691,7	8.361,5	9.558,0	9.352,1	11.154,0
São Paulo	49.988,6	55.025,5	61.542,9	74.394,5	76.513,3	89.517,1
R. G. do Sul	10.900,6	11.541,2	11.995,9	14.535,7	14.733,2	17.283,3
Amazonas	2.985,8	3.348,7	3.704,6	4.607,5	4.290,0	5.546,7

Fonte: Fonte: Elaborada pelo autor com base nos dados disponíveis nas respectivas Secretarias de Fazenda Estaduais.

A tabela 5 mostra a participação relativa do ICMS na receita corrente e tributária dos estados. Destaque para o peso do ICMS amazonense na receita tributária, principalmente se considerados os anos de 2005 e 2010, com respectivamente 93,05% e 93,15%.

Tabela 5 – Participação relativa do ICMS na receita (corrente e tributária) estadual, período 2005-2010, em percentual

Relação ICMS/Receita Corrente						
UF/ANO	2005	2006	2007	2008	2009	2010
Goiás	50,40%	52,00%	52,30%	52,30%	52,20%	53,00%
Bahia	45,40%	45,70%	47,70%	47,30%	44,70%	45,20%
São Paulo	67,70%	67,00%	66,70%	69,10%	67,30%	68,30%
R. G. do Sul	60,80%	59,90%	58,30%	58,90%	56,30%	56,10%
Amazonas	53,30%	54,60%	52,60%	53,80%	51,70%	55,10%

Relação ICMS/Receita Tributária						
UF/ANO	2005	2006	2007	2008	2009	2010
Goiás	83,34%	82,84%	82,29%	82,36%	80,78%	80,77%
Bahia	89,90%	89,24%	88,41%	87,80%	86,27%	86,62%
São Paulo	87,60%	86,76%	86,03%	86,76%	85,64%	86,73%
R. G. do Sul	86,31%	85,48%	84,24%	85,01%	82,50%	80,69%
Amazonas	93,15%	93,11%	92,81%	93,02%	92,42%	93,05%

Fonte: Fonte: Elaborada pelo autor com base nos dados disponíveis nas respectivas Secretarias de Fazenda Estaduais. Dados da pesquisa.

A tabela 6 mostra a divisão da arrecadação e de tributos estaduais levando-se em conta somente o valor total arrecadado pelos estados e Distrito Federal para os tributos ICMS, IPVA⁵ e o ITCMD⁶.

Observa-se na tabela 6 que, mesmo considerando o valor agregado desses impostos, a arrecadação do ICMS tem um peso significativo na arrecadação tributária estadual se comparada, por exemplo, ao IPVA e ao ITCMD. Em 2008, 83,09% da arrecadação tributária decorreu do ICMS.

Tabela 6 – Participação relativa (% total) dos principais tributos na arrecadação tributária dos Estados no Brasil, período 2006-2010

Tributo	Relação Tributo/Arrecadação tributária estadual (em %)				
	2006	2007	2008	2009	2010
ICMS	82,17%	81,89%	83,09%	82,96%	82,52%
IPVA	5,98%	6,39%	6,37%	6,49%	6,66%
ITCMD	0,47%	0,52%	0,55%	0,59%	0,75%

Fonte: Elaborado pelo autor. Dados disponíveis em RFB (2011).

⁵O IPVA é o Imposto sobre a Propriedade de Veículos Automotores.

⁶O ITCMD é o Imposto sobre a Transmissão *Causa Mortis* e Doações.

Portanto, os números apresentados nas tabelas anteriores mostram a importância que o ICMS tem na economia do país. Para os estados, esse imposto é crucial no financiamento dos projetos e investimentos do setor público.

1.5 A LEI DE RESPONSABILIDADE FISCAL E A PREVISÃO DA ARRECADAÇÃO RECEITA TRIBUTÁRIA

A Lei de Responsabilidade Fiscal (LRF), entre outras questões importantes, obriga os entes federados no Brasil a instituir, prever e arrecadar todos os tributos definidos na Constituição Federal de 1988 (BRASIL, 2000).

A LRF é a Lei nº 101, de 04 de maio de 2001. Ela tinha a ideia de que não era mais aceitável no Brasil se gastar mais do que se arrecada. Desta forma, ela buscava garantir que os responsáveis pelos recursos públicos no Brasil de alguma forma pudessem se comprometer em prol da dita “gestão fiscal responsável”.

Em linhas gerais, pode-se afirmar que a LRF foi criada em um período em que o Brasil passava por sérios problemas em seu balanço de pagamentos. Aliado a esse fato, o cenário externo também exacerbava o problema das contas públicas brasileiras. Foi nesse ambiente que nasceu a LRF, editada nos moldes de leis já existentes em outros países da Europa na década de 1990.

Outro aspecto importante da LRF diz respeito à obrigação dos entes federados em relação à previsão de receita pública. Essa imposição está delineada nos artigos 11 e 12 da referida lei. De maneira geral, o caráter obrigacional da previsão da receita pública pode ser considerado uma importante iniciativa que teve o poder público a fim de conter o ímpeto de gastança nos estados brasileiros a partir do ano de 2000.

A previsão da receita, segundo consta no artigo 11 da LRF, é vista como um dos “requisitos essenciais da responsabilidade na gestão fiscal” (BRASIL, 2000). Outro aspecto importante da referida lei insere-se no artigo 12; trata-se especificamente do modo como os entes deverão realizar a previsão dos tributos. A lei diz que:

As previsões de receita observarão as normas técnicas e legais, considerarão os efeitos das alterações na legislação, da variação do índice de preços, do crescimento econômico ou de qualquer outro fator relevante e serão acompanhadas de demonstrativo de sua evolução nos últimos três anos, da projeção para os dois seguintes àquele a que se referirem, e da metodologia de cálculo e premissas utilizadas (BRASIL, 2000).

Cabe um parêntese em relação ao que está definido no artigo citado. O que se observa nesta passagem da lei é que a previsão deve ser realizada levando-se em conta variáveis econômicas previamente definidas. Além disso, deve-se considerar também o efeito de alterações na legislação tributária e outros “fatores relevantes”. Em relação ao horizonte ou tempo de previsão, a lei indica um prazo de 24 meses, além de estar acompanhada da série histórica dos últimos 36 meses.

Em resumo, além de a LRF obrigar os entes a realizar a previsão, ela também sinaliza e indica, de alguma forma, o modo que se deve proceder para prever os recursos públicos arrecadados pela União, estados, Distrito Federal e municípios no Brasil.

1.5.1 A previsão

A previsão é uma atividade importante não somente para os governos. É uma temática que deve envolver governo e a sociedade em geral. Vale citar que, em última instância, os projetos de gastos e de investimentos públicos dependerão da efetiva entrada do dinheiro previsto. Nesse sentido, pode-se dizer que a previsão é um elemento imprescindível, pois a concretização de muitos investimentos será abortada se os valores arrecadados estiverem desalinhados do valor previamente orçado. Pode-se dizer, desta forma, que esse é um forte motivo a ser considerado no momento da elaboração da previsão da arrecadação tributária pelos gestores públicos ou aqueles que têm interesse nesta área.

Segundo Derrick (2002), a previsão de receita tributária é uma das tarefas mais difíceis e importantes no contexto do processo orçamentário governamental. O autor atribui essa dificuldade em função de a receita pública, na maioria das vezes, sofrer influências de fontes externas distintas. Outro ponto importante citado pelo autor diz respeito ao risco para as finanças do governo em se elaborar previsões

superestimadas ou subestimadas. Ele cita que uma projeção de receita muito abaixo do valor efetivamente arrecadado pode representar uma fonte de problemas, uma vez que projetos importantes deixam de ser inseridos no documento orçamentário anual em função de não se esperar o excesso de receita não previsto.

Por outro lado, e ainda pior, são previsões muito acima do valor efetivamente realizado pelos governos. Essa fonte de problema surge na medida em que a concretização de muitos projetos deverá ser deixada de lado, de tal sorte que o orçamento possa novamente alinhar-se com o valor efetivamente arrecadado e não o valor previsto não concretizado (DERRICK, 2002).

A atividade da previsão é uma tarefa muito comum em diversas áreas do conhecimento. Na economia, nos negócios, na meteorologia ou nas finanças é muito comum recorrer à tarefa da previsão a fim de fazer um planejamento ou até mesmo reduzir riscos.

O processo de previsão envolve situações distintas. Para Chatfield (2000), o mais importante é pensá-la como um meio de atingir um objetivo específico. Para o autor, a previsão não deve ter um fim em si mesma. Ela deve inserir-se em um contexto específico. Por exemplo, em algumas áreas, a previsão envolve decisões cruciais. Em uma situação empresarial, a previsão pode envolver situações estratégicas como lançar um novo produto no mercado ou decidir a quantidade a ser produzida no próximo Natal de um produto específico.

Quanto ao período, a previsão pode ser realizada para um longo ou curto prazo. Geralmente, a previsão de curto prazo envolve tomadas de decisões também para o longo prazo. Por outro lado, a previsão de longo prazo envolve questões de cunho estrutural. Por exemplo, o planejamento estratégico faz uso das previsões de longo prazo.

Chatfield (2000) adota três tipos de classificações para os modelos de previsão: a) quantitativo ou qualitativo; b) grau de intervenção humana; c) e o nível de complexidade. A previsão pode ser dividida também quanto ao tipo de modelo utilizado para prever os eventos futuros. Geralmente, divide-se em métodos quantitativos e qualitativos.

Os métodos qualitativos envolvem julgamentos pessoais. Um tipo importante de método qualitativo é o método Delphi. De maneira geral, o método Delphi está baseado no julgamento de uma especialista na área da variável a ser estimada. Este tipo de abordagem não se utiliza de modelos matemáticos e estatísticos para

realizar a previsão. O que se busca neste método é fazer inferência a partir do conhecimento dos especialistas.

Chatfield (2000) classifica os métodos quantitativos em univariados e multivariados. Os modelos univariados usam apenas informações de uma única variável para fazer projeções com base nos valores presentes e passados da própria série de dados. E os modelos multivariados adotam mais que uma série de dados na construção de modelos preditivos.

Por fim, quanto ao grau de complexidade, os modelos podem ser simples ou complexos. Os modelos univariados são exemplos de modelos simples. Na classe de modelos complexos estão os modelos multivariados (CHATFIELD, 2000).

1.5.2 A previsão de tributos: revisão da literatura

Geralmente, modelos de previsão de receita são utilizados para cumprir um dispositivo legal. No entanto, sua importância como ferramenta na gestão fiscal dever ser meta do governo e não deve somente ser considerado um esforço estatístico. Segundo Kong (2003), “[...] it is a public statement that many crucial budgetary decisions depend on”. Cita, em seguida, que a previsão confiável da receita é a base para uma disciplina fiscal e um orçamento executável.

Grizzle e Klay (2004) compararam os resultados de diversas técnicas de previsão com os dados dos impostos sobre vendas de 28 estados americanos. Para o estado americano da Califórnia, Kong (2007) procurou identificar as técnicas utilizadas para estimar o imposto estadual, bem como analisar quais dentre as técnicas analisadas produzem as estimativas mais acuradas e que apresentam menor desvio em relação ao efetivo valor arrecadado.

Há uma enorme dificuldade para realizar a previsão dos impostos, seja em decorrência do número elevado de variáveis que influenciam o efetivo valor a ser arrecadado, seja pela falta de preparação dos técnicos do governo. Sob essa ótica, cita Edwards (2010, p. 1), que afirma que “Government finances depend on a vast array of variables, but there is a clear hierarchy among them, and forecasting requires a parsimonious treatment of complicated budget rules and behavior”. Neste trabalho, o autor realça a importância da responsabilidade com a gestão de recursos

para o sucesso dos programas de transferências de recursos (EDWARDS, 2010, p. 2).

Os governos no Brasil não disponibilizam estudos com a metodologia adotada para estimar receitas tributárias, embora seja uma imposição legal. Nos EUA, o órgão encarregado de elaborar orçamento público federal, The Congressional Budget Office (CBO), elaborou e disponibilizou um trabalho onde consta o caminho percorrido para gerar os valores previstos. É muito claro o propósito do documento elaborado pelos técnicos do CBO, quando cita: “Developing budgetary and revenue forecasts to provide assumptions underlying congressional concurrent resolutions on the budget is an important function of the Congressional Budget Office” (CBO, 1983, p. ix). Nesse estudo, o CBO aponta como é constituído o modelo de previsão – “The CBO TAX Model”. Fundamentalmente, o modelo é constituído por 4 equações que determinam os componentes importantes do imposto ao longo do tempo (CBO, 1983, p. 12). Além disso, cita-se que:

When combined with current institutional information on stationary tax rates, brackets, and exemption levels, these equations permit forecasts of individual income tax liabilities and federal budget revenues from the individual income tax to be generated on the basis of a separate economic forecast of such variables as personal income, employment, and the price level. The model is designed specifically to account for the effects of several important recent and current developments on the income tax (CBO, 1983, p.12).

Os trabalhos de previsão de receita tributária no Brasil, geralmente, seguem o padrão de apresentar um modelo específico para ser adotado para predizer um determinado tributo, mormente o ICMS. Os trabalhos importantes na área de modelagem de tributos no Brasil são apresentados a seguir.

Em se tratando de literatura nacional, observa-se o desenvolvimento de diversos estudos na área de previsão de receitas públicas nos últimos 10 anos. O surgimento da Lei de Responsabilidade Fiscal, em 2000, pode ser considerado o fator preponderante que contribuiu para o aumento de publicações na área de previsão de tributos.

Assim, os estudos da área de previsão de receita pública no Brasil começaram a aparecer, principalmente, após o advento da LRF em 2001. Após o qual se encontra uma miríade de trabalhos que intencionam apresentar previsões mais precisas e acuradas a partir de modelos econométricos cada vez mais robustos e complexos.

Samohyl (2000) cita um trabalho para o estado de Santa Catarina com o intuito de apresentar uma previsão de curto prazo do ICMS de três setores: comércio, indústria e serviços. A metodologia utilizada por esse autor foi a mais comumente usada para fazer previsão dessa modalidade de variável econômica governamental, conhecida pelos nomes iniciais dos seus idealizadores, Box e Jenkins.

Arraes e Chumvichitra (1996) testaram o poder de previsão do modelo autorregressivo integrado e de média móvel (ARIMA) com os dados do ICMS do estado do Ceará para o período 1970-1995; nesse trabalho, utiliza-se a série trimestral do ICMS. A hipótese levantada pelos autores para justificar a construção de um modelo autorregressivo em detrimento ao causal é que “o modelo com informações incompletas pode gerar previsões tão acuradas quanto um modelo de previsão causal [...]” (ARRAES; CHUMVICHITRA, 1996, p. xx).

Para os tributos federais, pode-se citar o trabalho de Siqueira (2002), que adota a metodologia Box-Jenkins para construir um modelo alternativo passível de ser adotado pela Secretaria da Receita Federal do Brasil (SRFB). A modelagem abordada pelo autor no trabalho foi comparada ao modelo adotado pela SRFB, e sua conclusão foi a de que a previsão daquela instituição pode tornar-se mais acurada com a utilização de modelos alternativos ao que comumente é adotado.

Destacando a importância que o Estado deve dar à questão do planejamento orçamentário e fiscal, Silveira (2002) justifica a elaboração de um modelo de previsão para o estado de Goiás. Em seu trabalho, o autor partiu para a confecção de um modelo estrutural e escolheu o PIB como variável explicativa.

Sisnando e Freitas (2006) utilizam a metodologia conhecida como Redes Neurais Artificiais (RNA). Segundo os autores, o ambiente dinâmico é um fator limitador que contribui para dificultar os modelos convencionais em captar certos comportamentos dos contribuintes do ICMS. Ainda segundo eles, a metodologia RNA pode captar comportamentos bem melhor que os demais modelos, além de “tratar com o problema da instabilidade estrutural entre as observações de uma série com parâmetros não-lineares.”

Objetivando apresentar um modelo de previsão alternativo para o estado da Bahia, Marques e Uchôa (2006) desenvolveram o trabalho utilizando-se da técnica ARIMA. Sublinha-se a justificativa de não utilizar modelos causais ter sido motivada pela extrema dificuldade na escolha das variáveis explicativas. Cientes de que

modelos estruturais muitas vezes apresentam “viés e ineficiência dos estimadores”, esses autores optam pela escolha de um modelo alternativo que dispense a utilização do PIB como regressor, pois “os modelos de séries de tempos univariados do tipo auto-regressivo e de médias móveis (ARMA) têm sido amplamente empregados (...)”.

Na mesma linha de pesquisa, Campos (2009) constrói um modelo de previsão para três tributos federais, quais sejam: o Imposto de Importação (II), o Imposto de Renda das Pessoas Jurídicas (IRPJ) e a Contribuição para o Financiamento da Seguridade Social (COFINS). O autor objetiva criar um modelo alternativo para melhorar os resultados da previsão tributária dos tributos citados. Em sua pesquisa, o autor utiliza os modelos dinâmicos univariados e multivariados.

Em um trabalho também desenvolvido para o estado de São Paulo, Camargos (2008) se utiliza apenas da técnica de previsão ARIMA para desenvolver um modelo preditivo para os tributos de competência do estado de São Paulo (ICMS, IPVA, ITCMD e TAXAS).

Seguindo sistemática diferente, Liebel e Fogliatto (2005) apresentaram um modelo de previsão de receitas tributárias para o estado do Paraná. No entanto, os autores analisaram os resultados de diferentes modelos utilizados para realizar previsão de séries econômicas. Dentre os modelos de previsão escolhidos pelos autores, pode-se citar: (1) regressão linear; (2) suavização exponencial; (3) decomposição; (4) Box-Jenkins. Os resultados encontrados pelos autores para o tributo paranaense indicaram, após realização de testes e checagens, o modelo de suavização exponencial Winter aditivo.

Liebel e Neto (2006) compararam as metodologias SARIMA, das Redes Neurais e Holt-Winters para prever o ICMS de São Paulo, Rio de Janeiro e Pernambuco.

Outro trabalho pesquisado foi o de Contreras (2005), que desenvolve modelo de previsão para o ICMS nacional e para mais três estados brasileiros – Rio de Janeiro, Pernambuco e São Paulo. O método de previsão adotado foi o baseado em Redes Neurais. Segundo o autor, não obstante modelos baseados em Redes Neurais apresentarem resultados mais precisos que outros comumente adotados, os modelos mistos poderão contribuir para resultados ainda mais justos.

Corvalão (2002) aplica um tipo de metodologia ainda pouco adotado no Brasil para modelar receitas tributárias. Trata-se do emprego da abordagem geral para

específicos em modelos dinâmicos. Segundo Corvalão, essa abordagem, também conhecida como LSE, “foi desenvolvida a partir de pesquisas de Sargan na década de 60, e Davidson, Mizon e Hendry”. Essa abordagem diferencia-se das demais e tem uma característica bastante peculiar e interessante, pois, segundo ainda o autor:

É uma abordagem baseada num processo de redução sucessiva de um modelo econométrico geral, começando de um modelo estatístico dinâmico geral que captura as características essenciais do conjunto de dados. O ponto de partida deve ser um modelo dinâmico com uma ordem de defasagem grande o suficiente para incluir a defasagem verdadeira das variáveis e deve-se tentar evitar durante as reduções, a perda de informações importantes (CORVALÃO, 2002, p. 19).

Os resultados obtidos com a utilização dessa técnica, segundo autor, são bem melhores que os resultados obtidos com a técnica dos modelos univariados de série de tempo, como, por exemplo, modelos ARIMA. Em decorrência, o autor recomenda o uso de modelo dinâmico desse tipo para o estado do Paraná (CORVALÃO, 2002, p. 55). Para o estado do Paraná, Corvalão (2002, p. 55) tentou melhorar as previsões mensais do ICMS aplicando a metodologia de regressão denominada *London School of Economics* (LSE).

Com dados do ICMS de Pernambuco, Rio de Janeiro e São Paulo, Contreras (2005) realizou trabalho de previsão para avaliar a metodologia das redes neurais. Para o autor, a previsão com a metodologia ARIMA e a técnica do alisamento exponencial apresentam resultados inferiores se comparados à modelagem das redes neurais.

Em caráter de inovação, o modelo de previsão desenvolvido para o estado do Rio Grande do Sul apresenta características marcantes e diferenciadas nos demais modelos aqui analisados. Motivados pela falta de padronização na modelagem econométrica dos tributos gaúchos, Guaragna e Mello (2002) optaram por tentar construir uma “metodologia própria e inédita”, em que fosse possível inserir variáveis explicativas relevantes, como aquelas resultantes da política tributária e da administração tributária, além do cenário econômico.

2 PRINCÍPIOS ELEMENTARES DA ANÁLISE DE SÉRIES TEMPORAIS LINEARES

2.1 CONSIDERAÇÕES INICIAIS

No capítulo anterior, abordou-se a importância do ICMS para os estados brasileiros. Realçou-se também a obrigatoriedade imposta pela Lei de Responsabilidade Fiscal aos entes federados no Brasil no que diz respeito à previsão de recursos públicos arrecadados.

A previsão de tributos ou qualquer outra variável requer a adoção de um método específico, seja ele qualitativo, quantitativo ou uma combinação de ambos. Geralmente, a escolha do método de previsão envolve questões subjetivas, conforme preferência ou afinidade do previsor com uma abordagem ou técnica específica de análise.

Por outro lado, a escolha do modelo a ser utilizado depende também do acesso aos dados, da disponibilidade de *softwares* adequados e, principalmente, de uma equipe técnica qualificada. Todos esses fatores são importantes e contribuem na escolha e no resultado final da previsão da variável que se quer predizer (CHATFIELD, 2000).

O presente capítulo tem como objetivo apresentar os princípios básicos da análise de séries temporais. O arcabouço teórico que será apresentado neste capítulo tem grande importância para o objetivo do trabalho. Vale citar que o arcabouço metodológico disseminado por Box-Jenkins na década de 1970, e ainda hoje bastante utilizado em trabalhos empíricos, é simplesmente uma forma sistematizada que se utiliza dos instrumentos que serão vistos neste capítulo.

Portanto, o entendimento da metodologia Box-Jenkins passa necessariamente pelo entendimento da análise das séries de tempo lineares, tema abordado nas próximas seções.

2.2 ANÁLISE DE SÉRIES DE TEMPO LINEARES

Segundo Harvey (1993, p. 1), para o estudo das séries de tempo há dois aspectos importantes a ser considerados: **análise** e **modelagem**. Para ele, o objetivo da análise das séries de tempo é resumir as propriedades de uma série de dados e caracterizar suas principais características, e isso pode ser feito a partir do estudo do domínio do tempo ou da frequência⁷.

No que diz respeito à modelagem, o autor diz que o seu objetivo é principalmente permitir fazer previsão de valores futuros da série. Citam-se outros objetivos, tais como:

- a) **Obter** uma concisa descrição das características de um processo estocástico particular (VANDAELE, 1983, p. 8);
- b) **Construir** um modelo a fim de explicar o comportamento da série temporal em termo de outras variáveis (VANDAELE, 1983, p. 8);
- c) **Prever** condições econômicas futuras (LÜTKEPOHL; KRATZIG, 2004, p. 28);
- d) **Entender** o relacionamento entre as variáveis (LÜTKEPOHL; KRATZIG, 2004, p. 28);
- e) **Separar (ou filtrar)** o sinal-ruído da série (BROCKWELL; DAVIS, p. 1991, p. 8);
- f) **Controlar e otimizar** processos industriais (BOX; JENKINS; REINSEL, 2008, p. 2).

Cita Cochrane (2005, p. 9) que a maioria dos dados da área da macroeconomia e das finanças origina-se das séries de tempo. Mas, afinal de contas, o que é uma série de tempo? Uma série de tempo é uma sequência de observações ordenadas temporalmente, na maioria das vezes, estão dispostas em intervalos de tempo equidistantes. No entanto, as observações podem estar dispostas no tempo contínuo ou discreto, mas, usualmente, os dados da economia estão na forma de tempo discreto (CHATFIELD, 2000, p. 20).

Embora a teoria econômica tradicionalmente busque encontrar evidências que confirmem a suposta relação entre diferentes variáveis, na análise de séries

⁷No domínio do tempo, o foco é no relacionamento entre as observações em diferentes instantes do tempo; enquanto que o objetivo do domínio da frequência é estudar o movimento cíclico das séries (HARVEY, 1993, p. 1).

temporais univariadas isso não ocorre. Nesse tipo de abordagem, o comportamento da variável investigada é somente explicado pela própria variável. Esse tipo de abordagem não se preocupa, por exemplo, se uma alteração na legislação tributária em uma determinada unidade da federação implicará ou não aumento da arrecadação tributária após essa medida⁸.

Deste modo, mesmo havendo uma forte relação entre variáveis, na abordagem univariada das séries de tempo esse fator é irrelevante e não é levado em conta. Para esse tipo específico de análise, as respostas serão fornecidas somente a partir do conjunto de resultados estatísticos e probabilísticos extraídos da própria variável.

2.3 PROCESSOS ESTOCÁSTICOS

Definição. Seja $(\Omega, \mathfrak{F}, \mathbf{P}(\cdot))$ um espaço de probabilidade e T um conjunto de índices, um processo estocástico é uma função real $X(t, \omega)$ definida em $T \times \Omega$ tal que, para cada t fixo, $X(t, \omega)$ é uma variável aleatória em $(\Omega, \mathfrak{F}, \mathbf{P}(\cdot))$ (SPANOS, 1986, p. 131).

Dado o processo estocástico $\{X(t), t \in T\}$, apresentam-se algumas estatísticas importantes:

a) Média ou valor esperado

$$E(X_t) = \mu_t \quad (2.1)$$

b) Variância

$$E[(X_t - \mu_t)^2] = \sigma^2 \quad (2.2)$$

c) Covariância ou autocovariância (γ_k)

⁸Harvey (1993, p. 1) diz que nos modelos de séries de tempo, ao contrário dos modelos econométricos, não é feita nenhuma tentativa para formular o relacionamento comportamental entre as variáveis. Para Vandaele (1983, p. 8), a ideia de utilizar-se apenas o próprio conjunto de dados para realizar a previsão é a seguinte: o que está implícito na formulação de um modelo com apenas uma variável explicativa é que os demais fatores que influenciam a variável não alteram ou, da mesma forma, não se espera que mudem a tal ponto a justificar a inclusão destes fatores no modelo.

$$\text{Cov}(X_t, X_{t+k}) = E[(X_t - \mu)(X_{t+k} - \mu)] = \gamma_k \quad (2.3)$$

d) Correlação ou autocorrelação (ρ_k)

$$\text{Corr}(X_t, X_{t+k}) = \frac{E[(X_t - \mu)(X_{t+k} - \mu)]}{E(X_t - \mu)^2} = \frac{\gamma_k}{\gamma_0} = \rho_k \quad (2.4)$$

Para Maddala e Kim (2002, p. 8), a palavra ou termo estocástico origina-se do grego e significa pertencente à mudança. Em outras palavras, emprega-se o termo estocástico para expressar um fenômeno que evolui de acordo com uma lei probabilística. Assim, diferentemente de um processo determinístico – que evolui segundo uma lei matemática bem definida –, o processo estocástico pode ser entendido como um processo que evolui no tempo de maneira aleatória.

Para Harvey (1983, p. 9), cada observação de uma série de tempo pode ser pensada como um processo estocástico que evolui no tempo de acordo com certas leis probabilísticas.

Em síntese, uma série temporal pode ser entendida como uma realização de um processo estocástico. O importante é pensá-la como uma possível realização de um processo estocástico, e é a partir da existência dessa única realização que o analista deverá fazer inferências.

2.4 PROCESSO ESTOCÁSTICO ESTACIONÁRIO

Definição. Dado um processo estocástico $\{X(t), t \in T\}$, diz-se que esse é estritamente estacionário se para qualquer subconjunto $(t_1, t_2, \dots, t_k)$ de T , e qualquer k , tal que distribuição conjunta $F\{(X_{t_1}), \dots, F(X_{t_n})\} = F\{(X_{t_1+k}), \dots, F(X_{t_n+k})\}$.

Em outros termos, no processo estocástico estritamente estacionário a distribuição conjunta não depende do tempo (t), mas da distância temporal (k) entre as observações.

Na análise de séries de tempo, diz-se que a condição restrita da estacionaridade ser muito forte raramente é encontrada. Por isso, geralmente o conceito importante é o da estacionaridade fraca (ou de segunda ordem).

Definição. Seja o processo estocástico $\{X(t), t \in T\}$, diz-se que ele é fracamente estacionário (ou de segunda ordem) se satisfizer as seguintes condições:

a) Média for constante:

$$E(X_t) = E(X_{t+k}) = \mu \quad (2.5)$$

b) Variância for constante:

$$E(X_t)^2 = E(X_{t+k})^2 = \sigma^2 \quad (2.6)$$

c) Covariância que independe do tempo (t):

$$E[(X_t - \mu)(X_{t-k} - \mu)] = \gamma_k \quad (2.7)$$

Para Vandaele (1983, p. 14), para que se possa assumir que o valor observado em uma série de tempo seja representativo de seu valor médio, deve-se impor a restrição de média constante, conforme (2.5).

A segunda condição, mostrada em (2.6), informa que a variância do processo deve ser constante. Ainda na ótica de Vandaele (1983, p.14), não é correto supor que se pode expressar a incerteza em uma série de tempo se a variância está crescendo ao longo do tempo.

O processo estocástico que tem as características citadas acima é chamado de processo estocástico estacionário de segunda ordem, estacionário em covariância ou fracamente estacionário (ENDERS, 2010, p. 10).

Intuitivamente, o gráfico da série contra o tempo permite observar se uma série é ou não estacionária. A inspeção visual geralmente é a primeira tarefa executada pelo analista a fim de checar se a série é estacionária. No entanto, a maneira mais formal para checar se a série é estacionária é aplicando no conjunto de dados algum teste específico.⁹

⁹Na verdade, a inspeção visual do gráfico de uma série de tempo permite observar também as demais características da série: tendência, sazonalidade e ciclo. Os testes que permitem formalmente checar se uma série é estacionária serão mostrados em outra seção do trabalho.

2.5 RUÍDO BRANCO

Definição. Diz-se que o processo estocástico é um ruído branco se satisfizer as seguintes condições:

- a) Média igual a zero;

$$E(\varepsilon_t) = 0, \forall t; \quad (2.8)$$

- b) Variância constante;

$$E(\varepsilon_t^2) = \sigma^2, \forall t; \quad (2.9)$$

- c) Não correlacionado temporalmente;

$$E(\varepsilon_t \varepsilon_{t-k}) = 0, \forall k \neq 0 \quad (2.10)$$

O ruído branco (*innovation process*) é um processo estocástico de interesse no estudo das séries temporais. Segundo Tsay (2010, p. 36), uma série Y_t é dita ser um ruído branco se a sequência $\{Y_t\}$ de variáveis aleatórias for independente e identicamente distribuída (iid), com valor esperado igual a zero e variância finita. Particularmente, se o processo estocástico em questão for normal, a série é chamada então de ruído branco gaussiano.

2.6 A FUNÇÃO DE AUTOCORRELAÇÃO E AUTOCORRELAÇÃO PARCIAL

A correlação tem um importante papel da análise das séries de tempo. Ela ajuda a compreender a dinâmica de uma variada gama de modelos lineares. Segundo Tsay (2010, p. 29), a correlação entre uma variável e seus valores passados é o foco da análise das séries de temporais lineares.

Na análise de séries de tempo, particularmente na aplicação da metodologia Box-Jenkins, dois gráficos são importantes: o da função de autocorrelação (FAC) e o da função de autocorrelação parcial (FACP).

A autocorrelação é uma medida estatística que indica o grau de relacionamento temporal em uma série de tempo. Na análise de regressão linear, a correlação mensura o grau de relacionamento entre duas variáveis, X e Y.

Segundo Brockwell e Davis (1991, p. 29), as correlações positivas refletem a tendência de as sucessivas observações encontrarem-se acima do valor médio observado. Por outro lado, autocorrelações negativas refletem a tendência das sucessivas observações encontrarem-se abaixo de seu valor médio. A autocorrelação ρ_k mensura a correlação entre pares de observações afastadas k períodos de tempo. Os valores de ρ_k plotados contra o tempo (t) têm papel importante na abordagem Box-Jenkins e são denominados de função de autocorrelação (FAC), assim definida:

$$\rho_k = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} = \frac{\text{Cov}(X_t, X_{t+k})}{\text{Var}(X_t)} = \frac{\gamma_k}{\gamma_0} \quad (2.11)$$

Em um processo fracamente estacionário, X_t é não serialmente correlacionado se e somente se $\rho_k = 0$, para todo $k > 0$. Para as inferências a respeito do valor de ρ_k , adota-se um estimador consistente ρ_1 . Deste modo, se X_t for uma sequência independente e identicamente distribuída (iid), e for $E(X_t^2) < \infty$, então ρ_1 será assintoticamente normal com média zero e variância $1/T$.

Segundo Tsay (2010, p. 31), na prática usa-se o resultado mostrado acima para testar a hipótese nula de que ρ_1 seja igual a zero contra a hipótese alternativa de que ρ_1 seja diferente de zero. Pode-se realizar esse teste de forma individual ou conjunta. O teste individual para o coeficiente de correlação $H_1 : \rho_k \neq 0$ pode ser usado para testar se $H_0 : \rho_k = 0$ contra $H_1 : \rho_k \neq 0$. A estatística desse teste é:

$$t \text{ ratio} = \frac{\hat{\rho}_k}{\sqrt{(1 + 2 \sum_{l=1}^{l-1} \hat{\rho}_l^2) / T}} \quad (2.12)$$

Caso X_t seja um processo normal (ou gaussiano) estacionário, então $\rho_j = 0$ para $j > l$.

Pode-se também testar conjuntamente se vários coeficientes de autocorrelação são todos iguais a zero. Dois testes são comumente aplicados com esse objetivo: o teste de Portmanteau e o Ljung-Box. Frequentemente se adota o teste de Ljung-Box, que pode ser expresso da seguinte forma:

$$Q(m) = T(T+2) \sum_{l=1}^m \frac{\hat{\rho}_l^2}{T-l} \quad (2.13)$$

A hipótese nula do teste é que $H_0 : \rho_1 = \dots = \rho_m = 0$ contra a hipótese alternativa $H_1 : \rho_1 \neq \dots \neq \rho_m \neq 0$. Sob o pressuposto de que a série X_t é uma sequência (iid) e outras suposições adicionais em relação aos seus momentos de baixa ordem, a estatística $Q(m)$ é qui-quadrado com m graus de liberdade.

A escolha do m afeta a performance da estatística do teste $Q(m)$. No entanto, pode-se adotar a regra de bolso é usar um “ m ” aproximadamente igual ao logaritmo do número de observações (TSAY, 2010, p. 32).

O papel da FAC é mensurar o grau de relacionamento temporal linear de uma série de tempo. No entanto, ela considera também a correlação existente entre as observações que são adjacentes. Por exemplo, a correlação linear existente entre as observações afastadas por 2 períodos de tempo (ρ_k , com $k=2$) considera também a correlação existente nas observações adjacentes, ou seja, ρ_1 .

Muitas vezes, o interesse é saber a correlação “pura” entre as observações sem levar em conta as correlações intermediárias. Essa medida de correlação “pura” pode ser mensurada pela função de autocorrelação parcial (FACP).

Deste modo, a FACP pode ser entendida como uma medida de associação de dependência linear que leva em conta apenas o efeito direto (ou correlação pura) entre as observações. Assim, enquanto ρ_2 considera o efeito de ρ_1 , a função de

autocorrelação parcial (FACP) considera apenas o efeito das correlações puras entre as observações.

2.7 PROCESSO ESTOCÁSTICO AUTORREGRESSIVO

Um processo estocástico é dito autorregressivo se puder ser expresso como:

a) Autorregressivo de primeira ordem, ou AR (1);

$$AR(1): y_t = \phi_1 y_{t-1} + \varepsilon_t \quad (2.14)$$

b) Autorregressivo de segunda ordem, ou AR (2);

$$AR(2): y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t \quad (2.15)$$

c) Autorregressivo de ordem p, ou AR (p);

$$AR(p): y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.16)$$

Onde $\phi_1, \phi_2, \dots, \phi_p$ são constantes e ε_t é um processo de inovação (ou ruído branco).

O termo autorregressivo decorre do fato de o processo ser explicado pelos seus valores defasados. O termo “p” indica a mais alta ordem de defasagem do processo autorregressivo.

O processo AR (1) denotado em (3.1), por exemplo, tem uma estrutura de dependência temporal apenas na primeira defasagem.

Para um processo autorregressivo de segunda ordem AR (2), a estrutura de defasagem ocorre somente nas duas primeiras defasagens.

Generalizando, para um processo AR(p), a estrutura de dependência temporal tem a mais alta ordem na defasagem “p”.

Algumas características do processo são importantes. Por exemplo, para um processo tal como um $AR(1): y_t = c + \phi_1 y_{t-1} + \varepsilon_t$, tem-se:

a) Média:

$$E(y_t) = E(c + \phi_1 y_{t-1} + \varepsilon_t) = \mu = \frac{c}{1 - \phi_1} \quad (2.17)$$

b) Variância:

$$Var(y_t) = E(y_t - \mu)^2 = \frac{\sigma^2}{1 - \phi_1^2} \quad (2.18)$$

c) Primeira autocovariância:

$$\gamma_1 = \theta_1 \sigma^2 \quad (2.19)$$

d) Primeira autocorrelação:

$$\rho_1 = \frac{\left(\frac{\phi_1}{1 - \phi_1^2}\right) \sigma^2}{\frac{1}{1 - \phi_1^2} \sigma^2} = \phi_1 \quad (2.20)$$

Na análise das séries de tempo, impõem-se algumas restrições. Para os processos autorregressivos essa restrição é chamada de estacionaridade. A restrição imposta aos processos autorregressivos é que o valor absoluto de suas raízes (ou parâmetros) esteja fora do círculo unitário. Em termos paramétricos, a condição para que um processo $AR(1): y_t = c + \phi_1 y_{t-1} + \varepsilon_t$ seja estacionário é que $|\phi_1| < 1$. De maneira similar, para um processo $AR(2): y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t$ ser estacionário, é preciso que:

$$\phi_2 + \phi_1 < 1; \quad (2.21)$$

$$\phi_2 - \phi_1 < 1; \quad (2.22)$$

$$|\phi_2| < 1. \quad (2.23)$$

2.8 PROCESSO ESTOCÁSTICO MÉDIA MÓVEL

O processo estocástico é dito ser de média móvel (MA) se puder ser representado da seguinte forma:

a) Média móvel de primeira ordem, ou MA (1):

$$MA(1): y_t = a_t - \theta_1 a_{t-1} \quad (2.24)$$

b) Média móvel de segunda ordem, ou MA (2):

$$MA(2): y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad (2.25)$$

c) Média móvel de ordem q, ou MA (q):

$$MA(q): y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.26)$$

Onde, $\theta_1, \theta_2, \dots, \theta_q$ são constantes e a_t é um ruído branco.

O processo de média móvel, ou MA¹⁰, pode ser entendido como uma soma ponderada dos choques aleatórios presentes e passados. Da mesma forma vista no processo autorregressivo, o termo “q” é a mais alta ordem de dependência do processo. Por exemplo, para o processo MA (1), conforme mostrado em (2.13), existe estrutura de dependência temporal apenas na primeira defasagem do processo. A equação (2.26) mostra uma maneira possível de se expressar um processo estocástico de média móvel de ordem “q”, ou MA(q).

Os processos média móvel também têm características especiais. Por exemplo, dado um processo $X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1}$, pode-se mostrar que:

a) Média:

$$E(X_t) = E(\mu + \varepsilon_t + \theta_1 \varepsilon_{t-1}) = \mu \quad (2.27)$$

b) Variância

$$Var(X_t) = E(X_t - \mu)^2 = E(\varepsilon_t + \theta_1 \varepsilon_{t-1})^2 = (1 + \theta_1) \sigma^2 \quad (2.28)$$

¹⁰O termo médio móvel é o termo consagrado na literatura de séries temporais e vem da língua inglesa, significando *Movie Average* (MA).

c) Autocovariância (γ_1)

$$\text{Cov}(X_t, X_{t-1}) = \gamma_1 = \theta_1 \sigma^2 \quad (2.29)$$

d) Primeira autocorrelação (ρ_1)

$$\text{Corr}(X_t, X_{t-1}) = \frac{\gamma_1}{\gamma_0} = \rho_1 = \frac{\theta_1}{1 + \theta_1^2} \quad (2.30)$$

Diferentemente do processo autorregressivo, o processo média móvel é sempre estacionário, pois esse tipo de processo é uma combinação linear de uma sequência de ruídos brancos que tem os dois primeiros momentos invariantes no tempo (TSAY, 2010, p. 59). Desta forma, não é preciso se preocupar com a estacionaridade dos processos de média móvel (MA).

Assim, a suposição de estacionaridade (fraca) relaciona-se com os coeficientes do processo autorregressivo (AR). No entanto, quando se fala restrição do processo média móvel, o termo empregado é invertibilidade.

Deste modo, a restrição imposta aos processos média móvel é que eles sejam invertíveis. Para Pankratz (1983), algebricamente a condição de invertibilidade não difere da condição de estacionaridade vista no modelo autorregressivo, ou seja, para o processo $MA(1): X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1}$, a condição de invertibilidade é que $|\theta_1| < 1$.

Da mesma forma, um processo $MA(2): X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}$ será invertível se as seguintes condições forem satisfeitas¹¹:

$$\theta_2 - \theta_1 < 1 \quad (2.31)$$

$$\theta_2 - \theta_1 < 1 \quad (2.32)$$

$$|\theta_2| < 1 \quad (2.33)$$

Para processos $MA(q)$, com $q \geq 2$, segundo Pankratz (1993), o cálculo das condições de invertibilidade são complicados, mas deve-se checar ao menos se:

¹¹Essa abordagem leva em consideração os parâmetros do modelo MA. Pode-se também considerar as raízes características do polinômio, que deverão estar fora do círculo unitário para que o processo MA seja considerado invertível. O mesmo acontece com os processos autorregressivos estacionários.

$$\sum_{i=1}^q \theta_i < 1 \quad (2.34)$$

Da mesma forma que se deve evitar trabalhar com séries não estacionárias, existe uma forte razão para se evitar séries não invertíveis. Os processos não invertíveis darão pesos maiores às informações passadas. A ideia mais comum é pensar que as observações mais recentes sejam mais valiosas que informações passadas. Assim, a condição de invertibilidade do modelo garante que pesos menores serão atribuídos às informações mais distantes no tempo (PANKRATZ, 1983).

2.9 PROCESSO AUTORREGRESSIVO E DE MÉDIA MÓVEL

Dentro da família dos processos ARMA, pode-se também adotar uma combinação de parâmetros autorregressivos AR(p) e médias móveis MA(q), gerando os processos ARMA (p, q). Assim, considerando-se apenas a família dos processos estocásticos estacionários, o processo ARMA (p, q) pode ser representado por:

- a) Autorregressivo Média Móvel de ordem (p,q) = (1,1)

$$ARMA(1,1): Y_t = \phi_1 y_{t-1} + a_t + \theta_1 a_{t-1} \quad (2.35)$$

- b) Autorregressivo Média Móvel de ordem (p,q) = (2,1)

$$ARMA(2,1): Y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + a_t + \theta_1 a_{t-1} \quad (2.36)$$

- c) Autorregressivo Média Móvel de ordem (p,q) = (1,2)

$$ARMA(1,2): Y_t = \phi_1 y_{t-1} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} \quad (2.37)$$

- d) Autorregressivo Média Móvel de ordem (p,q)

$$ARMA(p,q): Y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (2.38)$$

As características dos processos mistos ARMA são mais complicadas, pois envolvem a mistura das características dos processos AR(p) e MA(q). Por exemplo, para o processo ARMA (1,1): $X_t = \phi_1 X_{t-1} + a_t + \theta_1 a_{t-1}$, tem-se:

a) Média

$$E(X_t) = E(\phi_1 X_{t-1} + a_t + \theta_1 a_{t-1}) \quad (2.39)$$

b) Variância

$$Var(X_t) = \gamma_0 = \frac{1 + \theta_1^2 + 2\phi_1\theta_1}{1 - \phi_1^2} \sigma^2 \quad (2.40)$$

O processo estocástico em (2.15) é dito um processo integrado autorregressivo média móvel. O termo integrado (I) denota processos não estacionários que se tornaram estacionários após serem diferenciados.

Na abordagem Box-Jenkins, a condição de estacionaridade da série é importante. No entanto, no mundo real, as variáveis não se comportam desta maneira. Em séries reais econômicas, por exemplo, é difícil encontrar esse tipo de característica.

Uma maneira de resolver o problema da não estacionaridade das séries de tempo é aplicando a diferenciação. Ou seja, tomam-se diferenças sucessivas de tal sorte que a série se torne estacionária. Assim, o termo I do acrônimo ARIMA indica a ordem de integração de uma série de tempo, ou seja, indica o número de vezes que a série precisou ser diferenciada para se tornar estacionária. Em geral, em dados econômicos, basta tomar uma ou duas diferenças para tornar a série estacionária.

2.10 PROCESSOS SAZONAIS

Em diversas ocasiões é comum se trabalhar com dados mensais ou trimestrais. Nestes casos, é comum também encontrar observações com estrutura de dependência temporal sazonal. Ou seja, para dados mensais é possível que observações para os meses de janeiro de um ano sejam altamente correlacionadas

com a observação referente ao mês de janeiro imediatamente anterior. Faz sentido, então, explorar a correlação existente entre meses ou trimestres iguais em anos sucessivos (VANDAELE, 1983, p. 53).

Deste modo, mesmo que as séries apresentem algum tipo de comportamento sazonal, elas ainda assim poderão ser usadas para construir modelos de previsão adotando igualmente as estratégias utilizadas no modelo ARIMA. Em síntese, a ideia de construir modelos com estrutura de dependência temporal periódica é pensar esse tipo de processo como filtro adicional a ser aplicado no processo: o filtro sazonal.

Segundo TSAY (2010, p. 82), em algumas aplicações, a sazonalidade tem pouca importância e, por isso, é retirada dos dados. Na visão de Johnston e Dinardo (1996, p. 575), as consequências em se utilizar os dados com ajuste sazonal dependerão da forma em que eles foram gerados e da natureza e do procedimento usado no ajustamento sazonal.

Os exemplos de processos estocásticos não sazonais apresentados anteriormente podem ser também observados na forma sazonal, quais sejam: Sazonal Autorregressivo (SAR), Sazonal Média Móvel (SMA) e Sazonal Autorregressivo Integrado Média Móvel (SARIMA).

3 A METODOLOGIA BOX-JENKINS

3.1 CONSIDERAÇÕES INICIAIS

No segundo capítulo deste trabalho, tratou-se da estrutura teórica da análise das séries de tempo. Neste terceiro capítulo, aborda-se a metodologia Box-Jenkins propriamente dita. Essa abordagem pode ser entendida simplesmente como um conjunto de procedimentos que o analista das séries temporais adota para construir um modelo de previsão, utilizando-se do arcabouço teórico discutido no segundo capítulo. Em outros termos, a metodologia Box-Jenkins faz uso de forma sistematizada dos processos estocásticos ARIMA. Em decorrência, os termos metodologia Box-Jenkins e metodologia ARIMA são usados de forma equivalente.

Sob uma ótica histórica, pode-se dizer que a revolução que ocorreu no estudo de séries temporais, após 1970, teve grande alcance a partir do tratamento que os estatísticos George E. P. Box e Gwilym M. Jenkins dispensaram ao assunto.

No entanto, apesar de os processos autorregressivos e de média móvel terem sido desenvolvidos, em princípio, por Yule (1929) e sistematizados por Wold (1938), foram os estatísticos George E. P. Box e Gwilym M. Jenkins os responsáveis pelo amplo emprego desses processos em trabalhos empíricos (KIRCHGÄSSNER WOLTERS, 2007, p. 4).

De um modo geral, a metodologia Box-Jenkins pode ser dividida em um conjunto de procedimentos ou fases, comumente classificados em três fases ou iterativas: identificação dos parâmetros, estimação dos parâmetros e checagem do diagnóstico ou validação.

O objetivo deste capítulo, portanto, é abordar cada uma das três etapas da metodologia Box-Jenkins. O capítulo também faz uma explanação a respeito da importante questão dos testes de raiz unitária. Existem vários testes para detectar o número de raízes unitárias em uma série de tempo. No entanto, foram selecionados apenas três testes, a saber: o teste de Dickey-Fuller (ADF), o de Phillips-Perron (PP) e o teste KPSS.

3.2 ITERAÇÃO E PARCIMÔNIA

A metodologia Box-Jenkins é um procedimento de três fases que adota o instrumental teórico da análise das séries temporais com o fito de construir um modelo de previsão de curto prazo de séries de tempo univariadas.

O caráter iterativo dessa abordagem é um dos principais motivos da metodologia ter se tornado amplamente utilizada em trabalhos empíricos. Além disso, o princípio 12 da parcimônia também tem lugar de destaque na abordagem.

Segundo Enders (2010, p. 78), a metodologia Box-Jenkins tem a parcimônia como princípio básico. A ideia da parcimônia na abordagem Box-Jenkins é que modelos com o menor número de parâmetros devem sempre ser preteridos. Na visão de Box, Jenkins e Reinsel (2008, p. 16), em situações práticas, é aconselhável construir um modelo que seja adequado, mas que também tenha o menor número de parâmetros possível. Igualmente, modelos com muitos parâmetros podem resultar em previsões pobres ou deficientes. Por isso, acrescentam os autores, devem-se empregar cuidados e esforços na seleção do modelo.

Similarmente, Pankratz (1983, p. 17) diz que um bom modelo, entre outros fatores, é aquele que tem o menor número de parâmetros necessários para estimar um modelo de forma adequada, considerando a série temporal disponível. Em outras palavras, a autor considera que a qualidade do modelo deve levar em consideração a questão da quantidade de parâmetros envolvidos na modelagem. Ou seja, considera-se bom aquele modelo ajustado corretamente, todavia seja dotado do menor número possível de parâmetros. Essa é a filosofia do princípio da parcimônia.

Na fase da identificação, visa-se descobrir os parâmetros que comporão a equação do movimento da série. Ou seja, tenta-se identificar a quantidade de parâmetros autorregressivos e de média móvel capazes de descrever o processo gerador dos dados.

Em um segundo momento, estimam-se os parâmetros identificados na fase inicial por algum método específico de estimação. A ideia nesta fase é buscar estimar parâmetros consistentes. A escolha do tipo e da quantidade de parâmetros

¹²O princípio da parcimônia é adotado em diversas áreas, tais como lógica, filosofia, matemática, ciência, etc. Este princípio é conhecido também como “A navalha de Ockham” (Occam’s razor).

identificados é importante, pois a qualidade da estimação dependerá, em última instância, dos parâmetros identificados na primeira fase (Box, Jenkins e Reinsel 2008, *passim*).

Após os parâmetros identificados e estimados, ainda não se sabe nada a respeito da validação do modelo. Então, é preciso realizar a checagem e tentar diagnosticar possíveis inconsistências na modelagem. Segundo Box, Jenkins e Reinsel (2008, p. 17), a validação tem o objetivo de descobrir o motivo do não ajustamento do modelo e tentar diagnosticar a causa.

Quanto ao caráter iterativo dessa metodologia, decorre do fato de poder retroceder em qualquer fase caso seja necessário realizar algum tipo de correção no modelo tentado. Por exemplo, na fase de identificação, é comum surgir equívocos em relação ao tipo de processo que melhor se ajusta aos dados. Neste caso, é comum também identificar várias subclasses de modelo a fim de conferir aquele que melhor se ajusta ao conjunto de dados. Esse procedimento pode ser repetido ou iterado quantas vezes forem necessárias para obter um modelo que se ajuste bem aos dados.

De modo idêntico, na etapa da validação o modelo estimado e identificado geralmente pode não apresentar certas características estatísticas desejáveis. Em decorrência do caráter iterativo da abordagem, permite-se, então, reidentificar e reestimar os parâmetros novamente a fim de melhorar a qualidade do modelo. Consequentemente, em função desse ciclo iterativo dessa abordagem em três fases, aliado também ao princípio da parcimônia, a metodologia Box-Jenkins tornou-se uma poderosa ferramenta para previsão de séries univariadas. As próximas seções tratarão de cada uma das fases da metodologia Box-Jenkins.

3.3 PREPARANDO OS DADOS

Para Hoff (1983, p. 30), “one of the biggest reasons for the failure in the application of time series forecasting methods is a misunderstanding of the nature of the data you are dealing with”. Para o autor, antes de aplicar a metodologia Box-Jenkins para construir um modelo de previsão, faz-se necessário coletar e qualificar os dados que serão utilizados na construção do modelo preditivo.

Conforme mencionado, a suposição da estacionaridade é condição básica da análise das séries temporais e, além disso, também é condição imposta no contexto metodológico da abordagem Box-Jenkins. Sob essa ótica, é recomendável checar, previamente, o estado geral dos dados. O procedimento padrão básico na análise das séries de tempo é primeiramente fazer uma inspeção visual na série de dados sob investigação (CHATFIELD, 2005, p. 6; VANDAELE, 1983, p. 16).

Tal procedimento tem diversos objetivos, tais como: conhecer as características da variável, como tendência, ciclo e componente irregular; verificar se há dados faltantes (*missing values*); averiguar o problema dos valores atípicos ou aberrantes (*outliers*); inspecionar se a série é estacionária (MONTGOMERY; JENNINS; HULAHCI, 2008, p. 5; BROCKWELL; DAVIS, 2002, p. 14).

Em outras situações, é preciso também averiguar se a série de dados original requer algum tipo de transformação. Geralmente, aplica-se alguma transformação na série original a fim de estabilizar a variância ou até mesmo torná-la estacionária (CHATFIELD, 2005, p. 13).

Outro tipo de transformação adotado comumente é a transformação logarítmica. Essa transformação geralmente é aplicada quando se almeja estabilizar a variância dos dados.¹³ No entanto, Box, Jenkins e Reinsel (2008, p. 384) dizem que é preciso cuidado na escolha do tipo de transformação aplicada da série original. Além disso, acrescentam que a inspeção visual do gráfico da série frequentemente pode sugerir o tipo de transformação requerida.

¹³A transformação logarítmica é um tipo de transformação Cox-Box. O mais correto é aplicar um teste a fim de se confirmar o tipo apropriado de transformação requerida. Para detalhes sobre os tipos de transformações, ver Cox-Box (1974).

Problema nos dados	Possível solução
Dados faltantes (<i>missing values</i>)*	Não aplicável na abordagem ARIMA
Valores atípicos (<i>outliers</i>)**	Modelável, mas pode ser corrigido.
Média não constante	Diferenciação
Sazonalidade	Diferenciação sazonal ou ajustamento sazonal
Variância não constante	Transformação (logarítmica ou raiz quadrada)
Raiz unitária	Teste de raiz unitária
Variância crescente	Aplicar o logaritmo na série original
Tendência Estocástica	Diferenciação
Tendência Determinística	Diferenciar ou destrendar ¹⁴ a série

Quadro 4 – Problemas comuns nas séries de tempo

Fonte: Elaboração própria baseada em Vandaele (1983 p. 16-30).

Nota: *Pode-se inserir algum valor, *ad hoc* ou por interpolação. **Pode ser alterado por um valor mais representativo, um método específico de ajustamento ou *ad hoc* (HOFF, 1983, p. 31-32).

Em relação aos resultados matemáticos e estatísticos apresentados pelo modelo, de acordo com Hoff (1983, p. 32-33), o analista ou previsor não deve cair na armadilha de acreditar unicamente nesses resultados, pois o perigo com a metodologia Box-Jenkins é acreditar somente nesses números e estatísticas apresentados. É preciso também usar o senso comum, pois a metodologia Box-Jenkins – não sendo uma caixa-preta – apresenta muitos aspectos julgamentais, acrescenta o autor.

3.4 TESTES DE RAIZ UNITÁRIA

A identificação é a fase da metodologia Box-Jenkins por meio da qual se escolhe a quantidade de parâmetros (autorregressivo e média móvel) que comporão o modelo preditivo da série observada. Nesta fase, permite-se também inferir a respeito da estacionaridade da série observando o comportamento da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP).

¹⁴Destrendar uma série significa remover sua tendência (determinística). A diferenciação, diferentemente, é o procedimento adotado quando uma série tem tendência estocástica. Os processos com tendência estocástica são ditos, por isso, serem um processo integrado. Ver Vandaele (1983, p. 20-25).

Entretanto, nem sempre é possível checar se uma série é estacionária apenas por meio da inspeção do correlograma amostral, principalmente na presença de modelos sazonais e/ou modelo combinados (ARIMA). Assim, uma forma de resolver essa questão é aplicando um teste formal para detectar se a série tem raiz unitária.

Na visão de Tsay (2010, p. 30), a base da análise da série de tempo é também a estacionaridade. Desta forma, faz-se necessário checar por meio de algum procedimento se o processo estocástico sob investigação caracteriza-se tal como um processo estacionário.

As séries não estacionárias geralmente tornam-se estacionárias após aplicação de uma ou duas diferenças. No entanto, existem testes estatísticos formais que podem testar a ordem de integração de uma série temporal: os testes de raiz unitária.

Nelson e Plosser (1982) – em artigo bastante citado na literatura dos testes de raiz unitária – afirmam que a representação apropriada da não estacionaridade é a questão estatística básica das séries temporais econômicas¹⁵.

Segundo Maddala e Kim (1998, p. 48), um processo que contém raiz unitária dificilmente pode ser adotado para fazer previsão. Isso ocorre em função de esse tipo de processo apresentar um padrão sistemático em seu movimento, que pode ser chamado de tendência estocástica.

A análise visual do correlograma como ferramenta para identificar se a série é estacionária pode ser substituída por testes estatísticos formais para confirmar a condição de estacionaridade de uma série temporal observada (MADDALA; KIM, 1998, p. 48).¹⁶

Na literatura das séries de tempo, um processo não estacionário é um processo que tem uma raiz unitária. Assim, quando os processos da família ARMA (p,q) forem não estacionários, eles serão expressos como ARIMA (p,d,q). A inclusão do termo I em ARIMA indica que o processo é não estacionário e integrado. O termo

¹⁵No citado artigo, Nelson e Plosser (1982) buscavam qualificar duas fontes distintas de não estacionaridade para dados de 14 séries da macroeconomia americana. Para eles, os processos não estacionários na média podem ser em decorrência de uma tendência estocástica (ou raiz unitária) ou de uma tendência determinística.

¹⁶Para compreender melhor o significado de um processo com tendência estocástica ver, por exemplo, Hamilton (1994). O livro de Maddala e Kim (1988) trata exaustivamente sobre os testes de raiz unitária.

integração decorre do fato de a série ter se tornado estacionária após ter sido diferenciada.

Portanto, a primeira diferença de uma série $X_t \sim I(d)$ é: $\Delta X_t = X_t - X_{t-1}$. Se uma série for diferenciada por duas vezes para se tornar estacionária diz-se que a série é integrada de ordem, ou $I(2)$.

Portanto, a ordem de integração de uma série de tempo traduz o número de diferenciação capaz de estacionarizá-la, e pode ser expressa como: $X_t \sim I(d)$, onde d é um número inteiro maior que zero. Nas séries econômicas, na prática, observa-se d igual a 1.

A proposta dos testes de raiz unitária, portanto, é testar a ordem de integração da série. Existem diversos testes de raiz unitária, mas somente três serão citados, são eles¹⁷:

- a) O teste de Dickey-Fuller (ADF);
- b) O teste de Phillips-Perron (PP);
- c) O teste de Kwiatkowski-Phillips-Schmidt-Shin (KPSS).

Os dois primeiros (a e b) têm hipótese nula de que o processo tenha uma tendência estocástica, ou seja, trata-se de processo com uma raiz unitária. O último teste a ser analisado, o KPSS, tem hipótese nula de que o processo estocástico seja estacionário. Outra característica desses testes é que eles testam apenas se a série tem uma raiz unitária.¹⁸

A versão ampliada do teste de DF inclui um número suficiente de defasagens, a fim de permitir que os erros do modelo sejam não correlacionados. O teste ADF pode assumir as seguintes formas:

Sem termos determinísticos;

$$\Delta Y_t = \varphi y_{t-1} + \sum_{i=1}^{p-1} \varpi_i \Delta y_{t-1} + \mu \quad (3.1)$$

¹⁷ADF é a versão aumentada do teste original de Dickey-Fuller.

¹⁸Dickey-Pantula (1987) desenvolveram um procedimento para se testar se uma série temporal tem múltiplas raízes.

Com termo constante;

$$\Delta Y_t = \alpha + \varphi y_{t-1} + \sum_{i=1}^{p-1} \varpi_i \Delta y_{t-1} + \mu \quad (3.2)$$

Com constante e tendência determinística;

$$\Delta Y_t = \alpha + \beta t + \varphi y_{t-1} + \sum_{i=1}^{p-1} \varpi_i \Delta y_{t-1} + \mu \quad (3.3)$$

O teste Phillips-Perron (PP) é um teste para detectar a presença de raiz unitária que difere dos testes DF e ADF. Phillips e Perron (1988) propuseram um método não paramétrico alternativo para testar a presença de raiz unitária. O teste PP decorre do teste de Dickey-Fuller, mas considera que a correlação serial não afeta a distribuição assintótica da estatística do teste. Assim, esse teste não necessita ser estimado com o termo de aumento, mesmo quando os termos de erros aleatórios não sejam um ruído branco.

O teste PP parte das mesmas premissas do teste de Dickey-Fuller, porém utiliza uma correção do teste baseada em um ajuste não paramétrico que corrige a presença da heterocedasticidade dos resíduos. Para esse teste, os valores das distribuições assintóticas são os mesmos do teste ADF, e as estatísticas dos testes dependem da especificação da parte determinística.

O teste de raiz unitária proposto por Kwiatkowski, Phillips, Schmidt e Shin (1992), mais conhecido na literatura dos testes de raiz unitária por KPSS, não decorre do teste ADF. Esse teste busca suprir a falha apresentada pelos testes de raiz unitária até então aplicados.¹⁹

Segundo os autores, os testes tradicionais (PP e ADF) constantemente falhavam em rejeitar a hipótese nula de uma raiz unitária²⁰. Desta forma, eles propuseram um procedimento alternativo que consistia em verificar a hipótese nula de série de tempo estacionária em torno de uma tendência determinística. Em outros termos, o teste KPSS tem hipótese nula de que a série observada é estacionária.

¹⁹Problemas com o poder e o tamanho dos testes ADF e PP. Ver Madalla e Kim (1988).

²⁰Por esse motivo, os testes ADF e PP são ditos testes de baixo poder. O baixo poder dos testes de raiz unitária refere-se à probabilidade de rejeitar a hipótese nula dado que ela seja falsa.

Assim, para obter confirmação sobre a condição de estacionaridade de uma série observada, propõem os autores, é útil tentar realizar tanto o teste que tem por hipótese nula de que a série tem uma raiz unitária bem como testar a hipótese nula de que a série seja um processo estacionário (KWIATKOWSKI; PHILLIPS; SCHMIDT; SHIN, 1992).

3.5 IDENTIFICAÇÃO

A primeira fase da metodologia é identificar os parâmetros do modelo. Isso pode ser realizado de modos distintos.²¹

- análise do correlograma, por meio da investigação do comportamento da FAC e da FACP;
- pela adoção de um critério de informação, comumente adota-se o Critério de Informação de Akaike (AIC) e o Critério Bayesiano de Schwarz (BIC)²²;
- complementarmente, adotando os procedimentos citados em (a) e (b).

Esta seção discorrerá sobre o procedimento de identificação dos parâmetros do modelo por meio da inspeção do correlograma (FAC e FACP) e pela adoção do critério de informação (AIC e BIC).

3.5.1 Análise do correlograma

O procedimento de identificação mais comumente adotado na metodologia Box-Jenkins ocorre por intermédio da inspeção visual e da análise das informações

²¹Não obstante o consenso sobre a utilização da FAC e da FACP como ferramentas poderosas nesta primeira fase da estratégia Box-Jenkins, atualmente outras ferramentas também são utilizadas no intuito de identificar modelos ARIMA. Ver, por exemplo, Choi (1992), que apresenta outras ferramentas utilizadas na fase de identificação de modelos da família ARIMA.

²²Outro critério de informação que também pode ser adotado na escolha de modelos alternativos é o Critério de Informação de Hannan-Quinn (QH).

estatísticas apresentadas no correlograma da série de tempo. Essas informações municiam o analista a decidir *a priori* o tipo e número de parâmetros previamente selecionados.

A fase de identificação Box-Jenkins consiste em determinar o número de parâmetro autorregressivo $AR(p)$ e de média móvel $MA(q)$ do processo estocástico. Segundo Choi (2002, p.2), como não se sabe *a priori* a verdadeira ordem do processo, deve-se determiná-la por meio das observações.

De acordo com Box, Jenkins e Reinsel (2008), identificar significa usar os dados ou qualquer outra informação como meio de conhecer o processo gerador da série a fim de sugerir uma subclasse de modelos que possa ser usada para inferência. Na visão de Enders (2010, p. 78), no estágio de identificação, o analista examina visualmente os dados plotados, a função de autocorrelação e a função de autocorrelação parcial.

O quadro abaixo mostra o resumo das características da FAC e da FACP teóricas dos processos ARMA. Essas características apresentadas no quadro 1 abaixo podem servir como um guia na fase de identificação. Em séries reais, dificilmente o comportamento da FAC/FACP seguirá o comportamento teórico esperado.²³

Atributos da FAC e da FACP dos processos não sazonais		
Processo	FAC	FACP
$AR(p)$	Declina globalmente	Truncada na ordem (AR) do processo
$MA(q)$	Truncada na ordem (MA) do processo	Declina globalmente
$ARMA(p,q)$	Declinante	Declinante

Quadro 5 – Atributos da FAC e da FACP
Fonte: Elaborada pelo autor.

Observa-se na tabela 8 que a identificação dos modelos autorregressivos puros deve ser realizada inspecionando a função de autocorrelação parcial (FACP). Por exemplo, o processo estacionário autorregressivo de primeira ordem, ou $AR(1)$,

²³No entanto, o comportamento teórico apresentado na tabela 8 pode municiar o analista de informações valiosas na escolha do modelo mais adequado para modelar a série de tempo.

é caracterizado por apresentar uma FAC que declina geometricamente para zero (ENDERS, 2010, p. 62).

Em relação à FACP do AR(1), geralmente ela é truncada na primeira correlação. Destaca-se que a convergência, se existir, poderá ocorrer de forma direta ou oscilatória, mas isso dependerá do sinal do parâmetro ser positivo ou negativo, respectivamente.

Atributos da FAC e da FACP dos processos sazonais ARMA (P^* , Q^*)		
Processo	FAC	FACP
Sazonal AR (SAR(P))	Picos nos lags (s) múltiplos sazonais (s, 2s,..., Ps)	Picos nos lags (s) múltiplos sazonais (s, 2s, ..., Ps); zero caso contrário
Sazonal MA (SMA(Q))	Picos nos lags (s) múltiplos sazonais (s, 2s,..., Qs), zero caso contrário	Picos decrescem exponencialmente a partir do lag múltiplo sazonal (s) e começa a lag s.
Sazonal SARMA (SARMA (P,Q))	Padrão irregular nos picos de defasagens de 1 a Q; as demais autocorrelações comportam-se como um processo AR não sazonal.	Padrão irregular nos picos de defasagens de 1 a P; as demais autocorrelações comportam-se como um processo MA não sazonal.

Quadro 6 – Atributos da FAC e FACP dos processos sazonais SARMA (P,Q)

Fonte: Adaptada (HOFF, 1983, p.191).

Nota: Para diferenciar a notação dos processos ARMA não sazonais, é comum indicar em caixa alta os parâmetros sazonais. Portanto, o modelo SARIMA (p,d,q)x(P,D,Q)s. As letras em caixa alta indicam os parâmetros sazonais. O **s** é a defasagem sazonal; s igual a 12 para dados mensais, s igual a 6 para dados semestrais e s igual a 4 para dados trimestrais.

3.5.2 Critério de informação

A seleção de modelos pode também ser realizada por intermédio do critério de informação. A inspeção do correlograma (FAC e FACP) de uma série é um procedimento subjetivo de identificação de modelos. Para suprir essa subjetividade e, ao mesmo tempo, aplicar uma ferramenta complementar de identificação paramétrica, pode-se recorrer ao uso do critério de informação.

Segundo Enders (2010, p. 70), a inclusão de parâmetros (AR e/ou MA) adicionais irá, certamente, reduzir a soma dos quadrados dos resíduos (SQR) estimados. Mas o problema da inclusão de parâmetros, acrescenta o autor, está na perda do grau de liberdade que ocorre em função da estimação de parâmetros adicionais. E, além disso, esses parâmetros adicionais reduzirão o desempenho da previsão.

Portanto, apesar de a análise do correlograma ser uma poderosa ferramenta de identificação, podem surgir dúvidas quanto ao número real de parâmetros a ser inseridos no modelo. Isso decorre, entre outros, pelo simples fato de a FAC e a FACP das séries reais não apresentarem o mesmo tipo de comportamento apresentado nas tabelas 7 e 8.

Portanto, a utilização do critério de informação insere-se neste contexto, ou seja, é uma maneira de dirimir dúvidas quanto ao número exato de parâmetros, considerando-se o *trade off* entre a redução da soma dos quadrados dos resíduos e a ideia da parcimônia. Lembrando que a adição de parâmetros, apesar de reduzir o número da soma dos quadrados dos resíduos, leva-nos a construir modelos com muitos parâmetros, portanto não parcimoniosos. Assim, a ideia do uso do critério de informação é dirimir esse *trade off* (SQR x PARCIMÔNIA).

A maioria dos *softwares* de econometria e estatística adotam mais que um critério de informação. No entanto, os dois mais comumente utilizados são AIC, devido a Akaike (1974), e o BIC, devido a Schwarz (1978). (ENDERS, 2010, p. 71). São os dois que serão estudados no trabalho.

Esses dois critérios se baseiam no valor da função de verossimilhança. O critério de informação de Akaike (AIC) – Akaike Information Criterion – tem a seguinte notação:

$$\bullet \quad AIC_{(p,q)} = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{T} \quad (3.4)$$

Onde p e q são a ordem dos modelos autorregressivos e média móvel, respectivamente; T é o número de observações da série de tempo; e $\sigma_{p,q}^2$ é a variância residual do modelo ajustado.

O segundo termo do lado direito da expressão (3.1) é o fator que penaliza a inclusão de parâmetros no modelo.

O critério de informação de Schwarz ou Bayseano (BIC) pode ser denotado por:

$$\bullet \quad BIC_{(p,q)} = \ln \sigma_{p,q}^2 + (p + q) \frac{\ln T}{T} \quad (3.5)$$

Onde p e q são a ordem dos modelos autorregressivos e média móvel, respectivamente; T é o número de observações da série de tempo; e $\sigma_{p,q}^2$ é a variância residual do modelo ajustado.

Similar ao critério AIC, o segundo termo da expressão (3.2) também é o termo penalizador da equação. Esse critério, conforme se observa em (3.2), penaliza de forma mais severa a inclusão de parâmetros. Por essa razão, deve-se optar sempre por ele.

A sistemática é que se devem escolher modelos com critérios de informação com o valor mais baixo. Isso é feito comparando modelos com amostras controladas. Amostras controladas são modelos com o mesmo número de parâmetro. Nessa abordagem, não se deve comparar modelos com número de observações que sejam iguais.

O procedimento de identificação dos processos sazonais é um pouco mais complicado do que aquele visto em modelos não sazonais. O comportamento da FAC e da FACP é mais complexo, pois envolve características do componente sazonal (mostrado nas defasagens dos períodos que são múltiplos sazonais) e as características da parte não sazonal. No entanto, podem-se identificar os modelos sazonais pela adoção de algum critério de informação e também pela análise do correlograma (FAC e PACP).

3.6 ESTIMAÇÃO

Para Box, Jenkins e Reinsel (2008, p. 231), a fase de identificação é apenas uma formulação não definitiva do modelo, mas em que ainda é preciso obter

estimativas eficientes²⁴ dos parâmetros. A estimação de parâmetros na metodologia Box-Jenkins pode ser realizada por qualquer método de estimação de parâmetros. Na maioria das vezes, utiliza-se o método da verossimilhança ou mínimos quadrados ordinários.

De qualquer forma, a intenção será sempre estimar parâmetros consistentes. Parâmetros consistentes é um conceito relacionado à lei forte dos grandes números. Para Casella e Berger (2010, p. 208), uma sequência da mesma quantidade amostral se aproxima de uma constante à medida que a amostra se aproxima do infinito.

Para Casella e Berger (2010, p. 281), o método da verossimilhança é o método para estimar parâmetros mais usados. De maneira geral, a estimativa de máxima verossimilhança é o valor do parâmetro para o qual a amostra observada é mais provável.

Formalmente, a estimação de parâmetros dos modelos da família ARIMA dependerá do tipo de parâmetro do modelo. Os processos autorregressivos puros podem ser estimados pelo método dos mínimos quadrados ordinários (OLS) ou máxima verossimilhança (MLE).

A ideia será encontrar parâmetros com a menor soma dos quadrados dos resíduos. No caso específico dos processos autorregressivos puros, não há diferença entre o método da máxima verossimilhança e mínimos quadrados ordinários (HAMILTON, 1994; BOX; JENKINS; REINSEL; BUENO, 2011). Assim, na maximização de verossimilhança, a exemplo do OLS, maximiza-se a verossimilhança e minimiza-se a soma dos quadrados dos erros ou resíduos.

A condição para estimar parâmetros pelo método da verossimilhança requer que os erros sejam ruídos brancos. No entanto, quando os erros não são ruídos brancos, mesmo assim os parâmetros serão consistentes, mas a estimação agora é chamada de quase-verossimilhança (HAMILTON, 1994).²⁵

Para estimação de um processo com termos de média móvel, a estimação ocorre por verossimilhança e requer um condicionamento do termo dos componentes não observados. Enders (2010, p. 116) diz que estimar parâmetros de

²⁴O termo eficiência atribuído aos parâmetros diz respeito à sua variância assintótica, portanto uma avaliação do desempenho do estimador quando a amostra tende ao infinito (LEHMANN; CASELLA, 1998).

²⁵Hamilton (1994) diz que a não normalidade pode ser corrigida após a aplicação de uma transformação logarítmica da série, que é uma forma especial de uma transformação Cox-Box.

média móvel difere da estimação dos parâmetros autorregressivos justamente pelo fato de os termos ou parâmetros de erros do processo de média móvel não serem conhecidos, precisando adotar um método de estimação da verossimilhança.

Na estimação de processo média móvel, Box, Jenkins e Reinsel (2008) sugerem condicionar o erro inicial igual a zero. Então, a partir desse condicionamento, os erros podem ser calculados iterativamente por meio de uma maximização numérica.²⁶

A estimação dos processos mistos (ARMA) requer condicionar o vetor de parâmetros autorregressivos (igual ao valor inicial das observações) e condicionar o vetor de erros (erros iniciais iguais a zero). Em outros termos, na estimação de um processo ARMA, condicionam-se as observações e o termo de erro inicial iguais aos seus valores esperados.

Um fato digno de nota da fase de estimação é que ela depende da maneira como foram escolhidos os parâmetros na fase de identificação. Evitar parâmetros redundantes pode contribuir para a convergência da estimação ocorrida com menos iteração. Deste modo, identificar parâmetros de maneira parcimoniosa contribui para uma estimação de melhor qualidade.

3.7 VALIDAÇÃO

O objetivo da terceira etapa da metodologia Box-Jenkins é validar o modelo previamente identificado e estimado. O modelo somente poderá ser utilizado para previsão após passar pela etapa de checagem e diagnóstico. Para Box-Jenkins e Reinsel (2008, p. 333), após o modelo ser ajustado (identificado e estimado), de alguma forma é preciso saber se este modelo estimado é adequado e, caso não seja, precisa-se saber também como ele poderá ser modificado; considerando o caráter iterativo da metodologia.

²⁶A condição de invertibilidade do processo de média móvel é uma questão relevante na fase de estimação, pois se os parâmetros estiverem fora do círculo unitário, portanto estiver na área de invertibilidade, o condicionamento imposto ao erro inicial igual a zero acumular-se-á ao longo do tempo. Mostra-se uma das razões de impor-se a condição de invertibilidade aos processos de média móvel.

Portanto, a validação do modelo – também conhecida na literatura por checagem e diagnóstico – pode ser entendida como um conjunto de testes que são aplicados aos resíduos do modelo construído a fim de checar a presença de certas qualidades do modelo 27.

Para Vandaele (1983, p. 125), a checagem e o diagnóstico do modelo são condições necessárias para se verificar a possibilidade de melhoria do modelo. Ele diz também que, se o modelo retrata adequadamente o processo ARIMA que governa a série de dados, os erros deverão ser um ruído branco (média zero, variância constante e finita e não correlacionado).

O que se deve ter em mente é que nesta abordagem busca-se sempre construir um “bom modelo”. Em se tratando de validação, um “bom modelo” deve ter resíduos estatisticamente independentes (PANKRATZ, 1983, p. 83). Ou seja, o desejo é encontrar erros não sistemáticos. Espera-se, então, aceitar a hipótese nula de resíduos não correlacionados. Com efeito, diz-se que toda a memória foi captada e o modelo pode ser usado para fazer previsão.

Assim, nesta etapa, aplicam-se alguns testes nos resíduos para garantir que os mesmos apresentem certas características desejáveis. Caso os testes não sejam satisfatórios, volta-se novamente para as fases anteriores (identificação e estimação) com o objetivo de encontrar resíduos normais, homocedásticos e não correlacionados serialmente. Box, Jenkins e Reinsel (2008, p. 335) sugerem como primeira etapa, nessa primeira fase, a inspeção visual do gráfico dos resíduos do modelo estimado.

Na análise residual, entre outros, busca-se verificar se os resíduos do modelo estimado são normalmente distribuídos. Para tal fim, aplica-se o teste de normalidade Jarque-Bera (1980). Esse teste baseia-se nos momentos de terceira e quarta ordens da distribuição. Ou seja, esse teste leva em consideração o valor do coeficiente de assimetria (A) e curtose (S) dos dados. Para erros normais, o coeficiente de assimetria deverá ser valor igual a zero. Em relação ao coeficiente de

²⁷Box-Jenkins e Reinsel (2008, p. 333) também citam o procedimento *overfitting*. Em linhas gerais, estima-se um modelo mais geral em relação ao modelo que se julga ser o mais adequado. A ideia é que os parâmetros adicionais deverão não ser significativos. Para os autores, no procedimento de *overfit* assume-se que se pode adivinhar a direção na qual o modelo provavelmente estará inadequado. Por esta razão, dizem, é preciso também complementar a validação do modelo por meio da análise dos resíduos.

excesso de curtose (K), para processos gaussianos ou normais, espera-se que o valor seja estatisticamente igual a três.

Enfim, o teste Jarque-Bera é um teste conjunto de assimetria e curtose aplicado aos resíduos do modelo. Neste caso, pode ser que a hipótese nula de normalidade seja rejeitada em função somente da falta de assimetria ou do excesso de curtose, ou ambas. Vale ressaltar que, geralmente, a presença de outliers e quebra estrutural podem ocorrer, por exemplo, em função do excesso de curtose nos dados. Neste caso, pode-se proceder ao exame dos dados originais a fim de checar com maior propriedade se existe uma explicação que fundamente corrigir ou expurgar outliers das séries de tempo.

O teste de Ljung-Box (1978) tem por meta detectar se um determinado conjunto (m) de resíduos é estatisticamente autocorrelacionado. Ou seja, o teste Ljung-Box testa a hipótese nula de independência serial dos resíduos para uma defasagem especificamente escolhida.

Para esse teste, espera-se não rejeitar a hipótese nula de resíduos não autocorrelacionados ou independentes. O mesmo tipo de teste pode ser executado com o correlograma do quadrado dos resíduos. Os resultados desses testes vão ser checados no correlograma dos resíduos e dos resíduos ao quadrado, respectivamente.

Alternativamente ao teste de Ljung-Box, pode-se adotar algum teste do tipo multiplicador de Lagrange (LM). O teste de correlação serial de Breusch-Godfrey é um teste do tipo multiplicador de Lagrange para checar a correlação serial residual do modelo estimado até uma defasagem previamente escolhida pelo analista.

Esse teste pode ajudar o analista a verificar se o modelo está mal especificado, ou seja, permite-se analisar se houve negligência em relação à inclusão de parâmetros importantes na modelagem. Existem ainda outros fatores que podem causar a correlação serial, tais como: componentes cíclicos; viés de variáveis omitidas, forma funcional mal especificada e manipulação de dados.

Em determinada situação, tem-se o interesse de modelar não somente o nível da série (média condicional), mas é comum também fazer inferência (e previsão) sobre a variância condicional da série. Sendo assim, pode-se realizar também o teste sobre o correlograma da série do quadrado dos resíduos. Esse teste é similar ao realizado na fase de identificação, ou seja, aplicam-se os convencionais testes individuais e conjuntos para detectar se os resíduos ao quadrado são ruídos

brancos. Neste caso, pode-se aplicar tanto o teste de heterocedasticidade dos resíduos ao quadrado ARCH teste (ENGLE, 1982) como também o teste White (1980).

O teste ARCH é um teste do tipo multiplicador de Lagrange para verificar a heterocedasticidade condicional autorregressiva dos resíduos. A hipótese nula do teste ARCH é que não há heterocedasticidade no quadrado dos resíduos, portanto variância constante. O teste White tem a mesma finalidade do teste Breusch-Godfrey, ou seja, é um teste para checar se os dados são homocedásticos. Portanto, a hipótese nula desse teste é para a não presença do efeito ARCH (heterocedasticidade autorregressiva condicional) no quadrado dos resíduos.

3.8 PREVISÃO

A responsabilidade de produzir e interpretar a previsão econômica requer um entendimento claro da ferramenta econométrica subjacente, seus limites e consciência de armadilhas comuns de uma aplicação (STOCK, 1999, p. 1).

Segundo Armstrong (1998, p. 449), em algumas situações a previsão é considerada como um mal necessário e é desaprovada, mas nos dias atuais a previsão parece ter se tornado uma atividade respeitável.

A previsão ou projeção linear na metodologia Box-Jenkins é uma afirmação condicional sobre o que ainda está por vir com base em suposições particulares (CHATFIELD, 1995, p. 76). Condicional, pois implica que a suposição que está sendo tomada está condicionada ao conjunto de informações ou conjunto de dados.

Um dos mais importantes objetivos da análise das séries de tempo é a previsão de valores futuros (WEI, 2006, p. 88). No entanto, o analista deve tomar alguns cuidados nesta etapa. Deve-se entender que o modelo não representa fielmente o verdadeiro processo que gerou os dados e por esta razão ele deve estar preparado para fazer os ajustes necessários à luz de quaisquer novas informações.

Assim, o previsor, ou a previsora, deve sempre buscar realizar a melhor previsão possível de sua variável. Ou seja, o modelo deve resultar em previsões acuradas. A ideia de acurácia no contexto da previsão de variáveis geralmente envolve uma medida: o erro de previsão. De posse do erro de previsão, pode-se

avaliar o desempenho do seu modelo. O erro de previsão simplesmente é o resultado entre a diferença do valor (efetivamente) e valor previsto (estimado) pelo modelo²⁸. Uma boa previsão, entre outras coisas, deve apresentar erro nulo ou o mais reduzido possível.

Segundo Armstrong (1992), a escolha da medida de desempenho envolve uma série de fatores como a quantidade de séries disponíveis ou se o objetivo for comparar ou calibrar o modelo. Existem diversas medidas de avaliação de modelos de previsão, no entanto, três são mais adotadas, a saber: (a) erro médio quadrático (MSE – Mean Square Error); (b) erro absoluto médio (MAE – Mean Absolute Error); (c) erro absoluto percentual médio (MAPE – Mean Absolute Percentual Error).

²⁸O resíduo do modelo de previsão estimado é simplesmente o erro de previsão um passo à frente.

4 APLICAÇÃO DA METODOLOGIA BOX-JENKINS

4.1 CONSIDERAÇÕES INICIAIS

Os dois capítulos precedentes abordaram o arcabouço teórico da análise de séries temporais. O segundo capítulo do trabalho mostrou os conceitos básicos que o analista ou previsor de séries de tempo deve dominar. O terceiro capítulo, por sua vez, apresentou os procedimentos que devem ser adotados para construir um modelo de previsão de séries univariadas, amplamente conhecido por metodologia Box-Jenkins.

A ideia central do quarto capítulo é construir um modelo de previsão para o ICMS utilizando-se dos instrumentos estudados nos dois últimos capítulos do trabalho. Este capítulo tem por objetivo também mostrar a metodologia adotada no trabalho a fim de elaborar um modelo de curto prazo para o ICMS para cinco estados brasileiros selecionados.

Além dessas considerações iniciais, o capítulo está estruturado em mais cinco seções. A segunda seção apresenta os dados da pesquisa, a metodologia adotada no trabalho e os *softwares* utilizados na pesquisa.

A terceira seção trata da análise de intervenção e dos modelos de transferência adotados no trabalho a fim de identificar eventos exógenos e seu impacto nos processos estocásticos estudados. A quarta seção seguinte apresenta os resultados dos testes de raiz unitária.

Os resultados dos testes de raiz unitária e da previsão estão no apêndice no final do trabalho. Os dados utilizados no trabalho também estão disponíveis no apêndice.

4.2 DADOS DA PESQUISA E METODOLOGIA

Os dados secundários da pesquisa são provenientes do *site* da Secretaria da Receita Federal do Brasil. São dados da arrecadação mensal do ICMS estadual no período de janeiro de 1997 a dezembro de 2011, totalizando 180 observações. Os dados coletados estão em valores nominais (em reais). Foi feita uma transformação logarítmica nos dados originais antes de dar início à modelagem.

Como forma de contemplar todas as cinco regiões do Brasil, será construído um modelo de previsão para cada uma das cinco regiões geográficas do país. Quanto aos estados selecionados, o critério escolhido foi o valor do ICMS arrecadado no ano de 2010. Em outras palavras, escolheu-se a Unidade Federal com maior volume de arrecadação do ICMS no ano de 2010 dentro da respectiva região, conforme apresentado na tabela 11.

Tabela 7 – Arrecadação do ICMS (participação relativa) de cada UF dentro da região em 2010

Região	Estado	Participação em 2010*
Sul	Rio Grande do Sul (RS)	42,50%
Sudeste	São Paulo (SP)	61,80%
Centro-Oeste	Goiás (GO)	35,90%
Norte	Amazonas (AM)	35,80%

Fonte: Elaborado pelo autor com base nos dados da pesquisa.

Nota: *Peso relativo da arrecadação do ICMS em 2010. Comparação efetuada entre os estados dentro da mesma região.

Quanto ao período selecionado para estimar os modelos – o conjunto de testes – será de janeiro de 1997 a dezembro de 2007. Os dados relativos ao período compreendido entre janeiro de 2011 e dezembro de 2011 serão utilizados para realizar a previsão.

Os testes de raiz unitária serão realizados por meio do *software* econométrico e estatístico Eviews7, enquanto que os modelos de previsão serão modelados pelo programa OxMetrics6.²⁹ Foram aplicados três de raiz unitária: ADF, PP e KPSS.

²⁹O programa X12ARIMA utilizado na modelagem é parte integrante do *software* OxMetrics6.

4.3 ANÁLISE DE INTERVENÇÃO, FUNÇÃO DE TRANSFERÊNCIA E A DETECÇÃO DE OUTLIERS

As observações das séries de tempo econômicas frequentemente são afetadas por eventos exógenos. Uma mudança na política econômica do governo, uma greve ou até mesmo um escândalo político podem afetar muitas séries econômicas. Segundo Box, Jenkins e Reinsel (2008, p. 529), o método para tratar essas intervenções é inserindo dois tipos de funções no modelo: uma função do tipo pulso (*pulse*) e/ou uma função *step*.

Em se tratando de uma variável como o ICMS, por exemplo, mudanças na legislação tributária geralmente alteram o comportamento da série a partir do instante de tempo em que for implementada. Outros aspectos podem também influenciar o comportamento da série do ICMS, tais como: a) taxa de câmbio (alterando a arrecadação do ICMS sobre os componentes importados utilizados na produção nacional); b) legislação tributária dos demais estados (incentivos estaduais fiscais, por exemplo, contribuem para exacerbar a guerra fiscal entre os estados); c) greve; d) escândalos políticos; e) eventos naturais de grandes magnitudes; f) crises internas e externas; g) calendário político.

Esses eventos, em algumas situações, podem resultar em observações extraordinárias que destoam da maioria das observações da série de tempo analisada. O resultado desses eventos atípicos sobre a série pode ter um efeito substancial no correlograma amostral (FAC e FACP), nos parâmetros estimados, na previsão e até mesmo na especificação do modelo (BOX; JENKINS; REINSEL, 2008).

Desta forma, é comum tentar captar esses efeitos introduzindo variáveis *dummies* (ou predeterminadas). Esse tipo de análise é chamado de análise de intervenção e a função utilizada é a função de transferência. As variáveis adotadas no modelo para explicar o comportamento da variável dependente são chamadas de variáveis indicadoras.

Portanto, um caso especial da função de transferência é a análise de intervenção, ou seja, medidas que afetam uma dada série de tempo. Neste tipo de análise busca-se avaliar o impacto de uma intervenção discreta sobre o processo estocástico. Segundo Vandaele (1983, p. 258), nesse tipo de análise a série será

usada para avaliar o impacto de uma intervenção (discreta) sobre o comportamento do processo.

De uma maneira geral, esses eventos atípicos podem ser modelados por meio da inclusão de variáveis *dummies* de dois tipos: a) *Additive outlier*, na qual se afeta o nível da série temporal observada apenas no tempo de ocorrência do evento; b) *Innovational outliers* (IA), um tipo de intervenção que afeta permanentemente a série observada.

A detecção de valores atípicos será feita no programa X12 ARIMA, que compõe o programa OxMetrics6.

4.4 RESULTADOS DOS TESTES DE RAIZ UNITÁRIA

O pressuposto básico para a previsão de séries de tempo na metodologia Box-Jenkins é a estacionaridade. Nesta seção, mostram-se os resultados dos testes de raiz unitária aplicados nas séries do ICMS dos estados. As tabelas 11 e 12 mostram o resumo dos resultados desses testes. Os resultados completos dos testes encontram-se nos anexos (A a E).

Foram aplicados testes para os todos os modelos³⁰ possíveis de cada um dos três testes realizados. Os testes foram aplicados no logaritmo das séries e também na primeira diferença do logaritmo das séries (taxa de crescimento, portanto).

Para o modelo com constante, os resultados sugeriram a favor da estacionaridade, portanto as séries têm tendência estocástica. A diferenciação das séries – procedimento padrão adotado em séries de tempo com tendência estocástica – foi capaz de torná-las estacionárias. Portanto, os testes aplicados nos modelos com termo constante foram unânimes a favor da não estacionaridade das séries. Portanto, séries são $I(0)$. A tabela 12 abaixo apresenta os resultados.

³⁰Os modelos testados foram: modelo com constante; com constante e tendência; e sem termos deterministas. Lembrando que o teste KPSS não testa o modelo sem termos determinísticos.

Tabela 8 – Resultados dos testes de raiz unitária para o modelo com constante

Estado	ADF		Phillips-Perron		KPSS	
	Nível	1ª Diferença	Nível	1ª Diferença	Nível	1ª Diferença
Amazonas	(1)-0.369	(0)-16.590*	0.127	-22.702*	1.705*	0.203
Bahia	(3)-0.721	(2)-12.265*	-0.878	-25.567*	1.711*	0.026
Goiás	(3)-0.251	(2)-12.300*	0.501	-32.152*	1.720*	0.202
São Paulo	(1)-0.261	(0)-19.197*	0.541	-35.410*	1.730*	0.301
R. G. Sul	(11)-0.684	(10)-9.028*	-0.868	-94.747*	1.716*	0.156

Fonte: Elaborado pelo autor.

Nota: *Rejeita-se a hipótese nula ao nível de 5% de significância. Os números entre parênteses no teste ADF referem-se à defasagem escolhida para tornar os erros não correlacionados (ou ruídos brancos).

No que diz respeito aos resultados dos testes aplicados aos modelos com tendência e constante, porém, não houve unanimidade entre os testes. Pelo contrário: os resultados foram conflitantes. Ora a favor da estacionaridade, ora contra. A tabela 13 apresenta os resultados.

Tabela 9 – Resultados dos testes de raiz unitária para o modelo com tendência e constante

Estado	ADF		Phillips-Perron		KPSS	
	Nível	1ª Diferença	Nível	1ª Diferença	Nível	1ª Diferença
Amazonas	(0)-5.789*	(0)-16.567*	-5.655*	-22.694*	0.098	0.118
Bahia	(2)-3.122	(2)-12.236*	-7.130*	-25.457*	0.345*	0.028
Goiás	(2)-4.369*	(2)-12.280*	-10.436*	-32.310*	0.153	0.085
São Paulo	(0)-8.079*	(0)-19.159*	-8.060*	-38.533*	0.102	0.123
Rio G. Sul	(0)-8.387*	(10)-9.022*	-8.877*	-94.783*	0.299*	0.154

Fonte: Dados da pesquisa.

Nota: *Rejeita-se a hipótese nula ao nível de 5% de significância. Os números entre parênteses no teste ADF referem-se à defasagem escolhida para tornar os erros não correlacionados (ou ruídos brancos).

Não houve evidências contra a hipótese nula de raiz unitária apenas para a série da Bahia. Portanto, para o modelo com constante e tendência determinística, a conclusão dos testes **ADF** é que todas as séries, exceto Bahia, são estacionárias em torno de uma tendência determinística e uma constante. Esses resultados contradizem os resultados dos testes aplicados nas séries sem o termo de tendência determinística.

Para o teste de raiz unitária Phillips-Perron (PP), no entanto, mostraram evidências estatísticas contra a hipótese nula de uma raiz unitária para todas as séries, o que também contradiz os resultados apresentados na tabela 12.

Por fim, o teste de **KPSS**, que, diferentemente dos demais, tem hipótese nula de que a série é estacionária, também apresentou resultados conflitantes. Por exemplo, para as séries de Goiás, São Paulo e Amazonas, não houve evidência para rejeitar a hipótese nula de que as séries são estacionárias. Portanto, o teste KPSS para essas três séries citadas indicou processos estacionários, ou seja, $I(0)$.

Sendo assim, os resultados do teste KPSS para Bahia e Rio Grande do Sul, aplicados aos modelos com constante e tendência determinística, estão alinhados com os resultados dos testes aplicados no modelo com o termo constante, que indicaram, da mesma forma, séries integradas de primeira ordem, ou seja, $I(1)$.

Por outro lado, os resultados dos testes KPSS para as séries do Amazonas, Goiás e São Paulo rejeitaram hipótese nula de raiz unitária. Portanto, para essas três séries em particular, os resultados desse KPSS são os mesmos apresentados pelos testes de Phillips-Perron e o ADF.

É importante levar em conta que incluir regressores no modelo sem necessidade pode reduzir a potência dos testes, e deixar de incluí-los, por outro lado, reduz a potência dos testes quando o tamanho da amostra cresce.

É muito importante, antes da modelagem Box-Jenkins, verificar se a série é ou não estacionária. Isso pode ser feito, conforme dito na parte teórica do trabalho, tanto pelo meio da análise do correlograma, como pelo teste formal de raiz unitária. Apesar de os testes apresentarem resultados conflitantes no que diz respeito à estacionaridade das séries, tomar-se-á a decisão pela não estacionaridade das mesmas em nível e pela estacionaridade de suas primeiras diferenças.

Portanto, com base no conjunto de resultados apresentados, assume-se que as séries seguem um processo integrado de primeira ordem, ou seja, são $I(1)$. E a construção do modelo de previsão Box-Jenkins será feita por meio da primeira diferença das séries. Segundo Campbell e Perron (1991, p. 11-12), a não rejeição da hipótese nula pode ser em decorrência da má especificação do modelo.

Modelo com constante							Modelo com constante e tendência					
Estado	ADF		KPSS		PP		ADF (4)**		KPSS (3)**		PP (5)**	
	Nível	1a. Dif.	Nível	1a. Dif.	Nível	1a. Dif.	Nível	1a. Dif.	Nível	1ª Dif.	Nível	1a. Dif.
Amazonas	Não	Sim	Não	Sim	Não	Sim	Sim*	Não	Sim*	Sim	Sim*	Sim
Bahia	Não	Sim	Não	Sim	Não	Sim	Não	Não	Não	Sim	Sim*	Sim
Goiás	Não	Sim	Não	Sim	Não	Sim	Sim*	Não	Sim*	Sim	Sim*	Sim
São Paulo	Não	Sim	Não	Sim	Não	Sim	Sim*	Não	Sim*	Sim	Sim*	Sim
R. G. do Sul	Não	Sim	Não	Sim	Não	Sim	Sim*	Não	Não	Sim	Sim*	Sim

Quadro 7 – A Série é (S) ou não (N) estacionária

Fonte: Elaborado pelo autor.

Nota: *Existência de conflito entre os resultados dos testes em relação ao modelo com tendência e constante e o modelo com constante apenas; **Os números entre parênteses informam a quantidade de resultados conflitantes em cada um dos testes. Por exemplo, no teste KPSS aplicado ao nível da série, apresentaram três resultados conflitantes em relação ao teste KPSS do modelo com uma constante.

Isso não ocorre com o teste aplicado no modelo com o termo constante apenas. O teste de PP rejeitou a hipótese nula de raiz unitária para todas as séries com tendência determinística e um termo constante. O teste ADF rejeitou a hipótese de raiz unitária para quatro séries. Para a série da Bahia não há evidências contra a hipótese nula de raiz unitária. O teste KPSS rejeita a hipótese nula de série estacionária para Bahia e Rio Grande do Sul. Os resultados dos testes com termos de tendência determinística e constante não foram conclusivos.

4.5 MODELOS ESTIMADOS E O RESULTADO DA PREVISÃO

Esta seção apresenta os modelos estimados e os resultados da previsão para cada um dos cinco estados selecionados para o ano de 2011. O quadro 7 resume os resultados. Os parâmetros de cada modelo encontram-se no apêndice dos trabalhos (quadros 6 a 15).

Estado	Erro anual (%)	Modelo estimado*	Quantidade de outliers	
			AO**	LS***
Amazonas	-3,46%	SARIMA (0,1,1)(0,1,1) ₁₂	01	01
Bahia	1,70%	SARIMA (2,1,0)(0,1,1) ₁₂	04	00
Goiás	8,16%	ARIMA(3,1,0)	02	00
São Paulo	-6,40%	SARIMA (0,1,2)(0,1,1) ₁₂	09	00
R. G. Sul	-0,26%	SARIMA (0,1,2)(0,1,1) ₁₂	01	00

Quadro 8 – Modelos de previsão estimados para o ICMS dos estados

Fonte: Dados da pesquisa.

Nota: (*) Em todos os modelos foram estimados com o termo constante. (*) e (**) referem-se aos valores atípicos *additive outliers* (AO) e *level shift* (LS), respectivamente.

A previsão para o ICMS para o estado de Goiás encontra-se na tabela 12. O modelo ajustado para o estado de Goiás foi um processo AR (3) com duas variáveis binárias (*additive outliers*³¹) para os meses de dezembro e abril de 2003. Para o estado de Goiás, tentou-se também fazer a previsão com outros modelos (sem as variáveis binárias), mas não houve melhoria na previsão com a retirada dessas duas variáveis do modelo. O erro de previsão do modelo estimado para o estado de Goiás para o ano de 2011 foi de 8,64%.

Apesar de o erro de previsão do modelo ter sido de quase mais de 8%, deve-se levar em conta que o valor da arrecadação do ICMS para o último mês do ano de 2011 deve ter influenciado neste resultado. Não foi realizada nenhuma pesquisa junto à Secretaria de Fazenda de Goiás para averiguar o porquê do crescimento nominal da arrecadação do mês de dezembro de 2011 ter sido 71,2% maior que o mês anterior e ter apresentado 84,9% de crescimento em relação ao mês de dezembro 2010.

Esse resultado, por exemplo, pode ser reflexo de alguma arrecadação extemporânea por parte de alguma grande empresa do estado de Goiás, ou até mesmo uma antecipação generalizada do tributo por parte dos contribuintes daquele estado.

O segundo modelo apresentado é o modelo do estado do Rio Grande do Sul. O erro percentual anual da previsão foi de apenas 0,26%. O modelo se ajustou muito bem aos dados do ICMS mensal do estado do Rio Grande do Sul. O modelo

³¹Os valores atípicos ou outliers são classificados em: Additive outlier (AO) e Level Shift (LS) e Innovate outliers (IO). Taylor e Burrige (2006) apresentam três motivos que o analista tem para checar a existência de valores extremos (*outliers*) na série de dado. Disponível no seguinte endereço eletrônico: www.cemmap.ac.uk/events/esg_annual05/burridge.pdf.

final estimado foi do tipo autorregressivo sazonal integrado média móvel SARIMA $(0,1,0) \times (2,1,1)_{12}$ com uma variável binária (AO) para o mês de junho do ano de 2003.

Para o estado do Rio Grande do Sul, estimaram-se outros modelos sem a presença da variável binária e sem a presença do termo constante. Além disso, tentou-se também estimar modelo sem a presença do componente sazonal. Não obstante, o modelo que mais se ajustou aos dados e apresentou menor erro percentual foi o SARIMA $(0.1,0) (2,1,2)_{12}$.

O modelo do estado de São Paulo apresentou um modelo SARIMA com mais nove *dummies*. O modelo final foi um SARIMA $(0, 1,2)(0,1,1)_{12}$ com mais nove variáveis *dummies* (tabela 6). Tentou-se retirar algumas das variáveis *dummies* do modelo, mas não foi possível melhorá-lo.

O modelo de previsão paulista previu valor de R\$ 6,5 bilhões acima do valor efetivamente arrecadado pelo estado de São Paulo em 2011, que foi da ordem de R\$ 102,14 bilhões. O erro anual do modelo de previsão de São Paulo foi de -6,4% (apresentado no Apêndice D).

O modelo de previsão da Bahia apresentou erro de 1,7% para o ano de 2011. O modelo final foi um SARIMA $(2,1,0)(0,1,1)_{12}$ com quatro variáveis *dummies* (ver tabela 23 do apêndice). Os modelos sem análise de intervenção para o estado da Bahia também não melhoram a previsão para o ano de 2011.

O modelo final escolhido para o estado da Bahia estimou uma arrecadação de R\$ 12,983 bilhões para o ano de 2011. A arrecadação do ICMS efetiva foi de R\$ 13,208 bilhões, resultando em erro de R\$ 225,00 milhões.

O modelo de previsão do estado do Amazonas foi um SARIMA $(0,1,1)(0,1,1)_{12}$ com duas variáveis binárias.

Diferentemente dos demais modelos, o modelo final do Amazonas apresentou uma *dumme* do tipo *level shift* (LS). Esse tipo de variável indica que houve mudança permanente no nível da série após o mês de janeiro de 2009. Esse resultado pode ser sido influência da Crise de 2008.

Esse fato revela uma questão importante que diz respeito à estrutura da economia amazonense. A economia do Amazonas sentiu mais rapidamente os efeitos da Crise de 2008 que os demais estados. A arrecadação do ICMS amazonense é bastante dependente do faturamento do Polo Industrial de Manaus

(PIM), que em 2009 teve uma retração de 6,83%³² em relação ao ano de 2008. Assim, o modelo capturou a mudança tanto no nível (AOFEV199) quanto na inclinação da série (LSJAN2009).

Assim como foi feito para os demais modelos, tentou-se retirar essas variáveis binárias na tentativa melhorar a previsão; no entanto, na retirada, o melhor modelo foi mesmo com a inclusão dessas duas variáveis *dummies*. O modelo de previsão do ICMS do estado do Amazonas (Apêndice C) apresentou erro superior a 12% (mês de outubro de 2011). O modelo apresentou erro de -3,46% para o ano de 2011.

Os resultados dos testes de raiz unitária, da previsão e os parâmetros de cada modelo estimado estão no apêndice no final do trabalho.

³² O faturamento do Polo Industrial de Manaus foi de R\$ 54.243.035.379,00 em 2008 e R\$ 50.539.531.703,00 em 2009. Dados são da Suframa (Superintendência da Zona Franca de Manaus). Disponível em: <http://www.suframa.gov.br/download/indicadores/indicadores-desempenho-pim-fevereiro-2012-03042012.pdf>. Acesso em: 30/03/2012.

CONSIDERAÇÕES FINAIS

O objetivo do trabalho foi construir um modelo preditivo para a série de dados da arrecadação mensal do tributo estadual ICMS adotando a metodologia Box-Jenkins. Os resultados da previsão da arrecadação do ICMS dos cinco estados apresentaram-se satisfatórios, levando-se em conta unicamente o erro de previsão para o ano de 2011.

A importância de uma previsão acurada de uma variável tão relevante quanto o ICMS pode ser vista sob distintos aspectos. Sob o ponto de vista prático, pode ser útil como guia para elaboração do orçamento anual dos estados brasileiros. Sob o aspecto legal, deve ser encarada como uma medida de gestão responsável e transparente. Além disso, a previsão de recursos públicos no Brasil é de cunho compulsório.

A modelagem adotada neste trabalho para prever ICMS estadual tem caráter ateuórico. Ela não visa, por exemplo, explicar o comportamento do imposto por meio do arcabouço teórico da economia ou das finanças públicas. O comportamento da variável é única e exclusivamente explicado pela estrutura de dependência temporal existente no conjunto de informações (dados) disponíveis. Sob essa ótica, a modelagem pode ser uma alternativa razoável para prever um tipo de variável com as características do imposto.

O grau de complexidade de uma variável como o ICMS torna árida a tarefa de construir um modelo causal. Ressalta-se que a tarefa de identificar variáveis que sensibilizam mais diretamente esse tipo de imposto muitas vezes pode ter efeitos ambíguos. Por exemplo, o efeito da legislação tributária ou efeito da inflação sobre a arrecadação desse imposto *a priori* não é conhecido.

Com efeito, os métodos de previsão de séries temporais univariadas podem ser empregados como tentativa inicial de modelagem. Assim, a previsão para o curto prazo dos estados foi realizada por meio da metodologia amplamente conhecida pelo nome dos autores que sistematizaram e difundiram o emprego dos processos da família ARIMA.

De um modo geral, essa metodologia pode ser de grande valia quando a intenção é fazer uma previsão de curto prazo de séries univariadas. Por exemplo, se a intenção for estimar o valor do ICMS para o período de apenas um ano –

elaboração do orçamento anual – essa metodologia pode ser facilmente aplicável, necessitando apenas do *software* adequado e um analista ou previsor com conhecimentos estatísticos e probabilísticos de análise de séries de tempo lineares.

Por outro lado, essa metodologia não é adequada para fazer previsões de longo alcance e nem deve ser adotada como ferramenta de apoio na tomada de decisões de políticas públicas, situações que demandam trabalhar com modelos com variáveis exógenas predeterminadas.

As limitações do trabalho são de múltiplas fontes, que podem ser divididas da seguinte forma: a) limitações no que concerne à atividade da previsão; b) limitações no que diz respeito aos dados do trabalho; e c) limitações concernentes à metodologia empregada.

A primeira limitação decorre da falta natural do conhecimento do que ainda estar por vir. Além do mais, é preciso estar ciente de que muitas vezes as falhas em prever certo tipo de comportamento ou fenômeno ocorrem pelo simples fato de não saber o que realmente não sabemos (MAKRIDAKIS, 1999). Neste caso, as falhas não se relacionam ao tipo de modelo empregado, mas sim ao próprio desentendimento do fenômeno estudado.

Um segundo tipo de limitação identificada é aquela oriunda da falta de conhecimento no que diz respeito aos dados da pesquisa. É importante deixar claro, portanto, que existe uma limitação que diz respeito aos dados adotados na construção do modelo de previsão do trabalho. Os resultados poderiam ser melhorados, talvez, caso se conhecesse melhor cada uma das séries de tempo modeladas.

O analista ou previsor deve conhecer, antes de mais nada, e, na medida em que for possível, os aspectos mais importantes da variável estudada. Com isso, é preciso deixar claro que o analista ou previsor, sendo especialista na área na qual sua variável está sendo modelada, pode melhorar a qualidade da previsão na medida em que ele é capaz de explicar os movimentos no conjunto de dados a partir de informações específicas.

A terceira limitação do trabalho diz respeito ao tipo de abordagem empregada. Apesar de essa ferramenta de análise ainda ser amplamente empregada em trabalhos empíricos, ela está limitada aos modelos lineares. Evidências empíricas têm mostrado que muitas variáveis, sobretudo no campo das finanças, apresentam

estruturas não lineares. Desta forma, os modelos tradicionais Box-Jenkins falham ao não captarem a estrutura não linear nos dados.

Outro tipo de limitação da metodologia Box-Jenkins diz respeito ao forte pressuposto da estacionaridade das séries. Caso se leve em conta que a grande maioria das variáveis econômicas apresenta-se com algum tipo de crescimento e/ou tendência, essa metodologia pode ser não aplicável.

Considerando-se a importância do ICMS para as finanças públicas dos estados no Brasil e, considerando-se também as diversas limitações apresentadas pela abordagem Box-Jenkins, a proposta para trabalhos futuros é estudar e aplicar outras abordagens modelagens disponíveis, a fim de construir um modelo de previsão para o médio e longo prazo do ICMS dos estados brasileiros.

REFERÊNCIAS

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, p. 716-723, 1974.

ARMSTRONG, J.S. Research Needs in Forecasting. **International Journal of Forecasting**, v. 4, p. 449-465, 1988.

ARRAES, R.A.; CHUMVICHITRA, P. **Modelos autoregressivos e poder de previsão: uma aplicação com o ICMS**. Programa de Pós-Graduação em Economia, Universidade Federal do Ceará, 1996. (Texto para Discussão nº 152).

BOX, G.E.P.; JENKINS, C.M.; REINSEL, G.C. **Time series analysis: forecasting and control**. 4. ed. New York: Prentice-Hall, 2008.

BRASIL. **Lei Complementar nº 87, de 13 de setembro de 1996** [Lei Kandir]. 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.

BRASIL. **Lei Complementar nº 101, de 04 de maio de 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.

BRASIL. **Constituição** (1988). Constituição da República Federativa do Brasil: promulgada em 5 de outubro de 1988.

BRASIL. Carga Tributária do Brasil em 2010: análise por tributo e base de incidência. **Receita Federal do Brasil**. Set. 2011. Disponível em: <<http://www.receita.fazenda.gov.br/Publico/estudoTributarios/estatisticas/CTB2010.pdf>>. Acesso em: 20 nov. 2011.

BREUSCH, T.S.; PAGAN, A.R. Simple test for heteroscedasticity and random coefficient variation. **Econometrica** (The Econometric Society), v. 47, n. 5, p. 1287-1294, 1979.

BROCKWEL, P.J.; DAVIS, R.A. **Introduction to time series and forecasting**. E. ed. New York: Springer, 2002.

BUENO, R.L.S. **Econometria de séries temporais**. 2. ed. São Paulo: Cengage Learning, 2010.

BURRIDGE, P.; TAYLOR, A.M.R. Additive outlier detection via extreme-value theory. **Journal of Time Series Analysis**, v. 27, p. 685-701, 2006.

CAMPOS, C.V.C. **Métodos econométricos aplicados à previsão da arrecadação de receitas federais**. Receita Federal do Brasil. ESAF, 2009.

CARDOSO, A.T. **Não-cumutatividade do ICMS**: dimensão normativa e eficácia. Porto Alegre: Livraria do Advogado, 2009.

CASELLA, G.; BERGER, R. **Inferência estatística**. 2. ed. Tradução de Solange A. Visconde. São Paulo: Cengage Learning, 2010.

CASTANHO, B.J.S. **Modelos para previsão de receitas tributárias**: o ICMS do estado do Espírito Santo. 119f. Dissertação (Mestrado em Economia) – Centro de Ciências Jurídicas e Econômicas, Universidade Federal do Espírito Santo, Vitória, 2011.

CBO. **Congressional Budget Office**. Forecasting Individual Income Tax Revenues: a technical analysis. (1983). Disponível em: <<http://www.cbo.gov>>. Acesso em: 30 mar. 2010.

CBO. **Congressional Budget Office**. How CBO forecasting income (2006). Disponível em: <<http://www.cbo.gov/sites/default/files/cbofiles/ftpdocs/75xx/doc7507/08-25-income.pdf>>. Acesso em: 30 mar. 2010.

CHATFIELD, C. **Times-Series Forecasting**. Department of Mathematical Sciences, University of Bath, UK. Chapman&Hall/CRC, 2000.

CHOI, B. **Arma model identification**. Spring Verlag. New York, 1992.

COCCARO, Suzana Menna Barreto. **A arrecadação do ICMS-RS**: um enfoque econométrico. Programa de Pós-Graduação em Economia, Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

COCHRANE, J.H. **Times series for macroeconomics and finance**. Notas de aula, 2005. Disponível em: <http://www.faculty.chicagobooth.edu/john.cochrane/research/papers/time_series_book.pdf>. Acesso em: 20 mar. 2012.

CORVALÃO, E.D. **Previsão da arrecadação do ICMS em Santa Catarina**: aplicação da abordagem geral para específico em modelos dinâmicos. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, 2002. Disponível em: <http://www.senado.gov.br/conleg/textos_discussao.htm>. Acesso em: 23 dez. 2011.

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

DURBIN, J.; KOOPMAN, S.J. **Time series analysis by state space methods**. Oxford: University Press, 2001.

EDWARDS, R.D. Forecasting government revenue and expenditure in the U.S. using data on age-specific utilization. **National Transfer Accounts Project Working Paper**, 2010.

ENDERS, W. **Applied econometric time series**. 3. ed. New Jersey: Wiley, 2010.

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

FREITAS, M.A.S.; SISNANDO, S.R.A. O emprego de rede neurais artificiais na previsão e avaliação do desempenho dos contribuintes do ICMS do estado do Ceará. **Revista Econômica do Nordeste**, Fortaleza, v. 37, n. 1, p. 131-149, jan./mar. 2006.

GRIFFITHS, W.E.; HILL, R.C.; Judge, G.G. **Learning and practicing econometrics**. New York: Wiley, 1993.

GRIZZLE, G.A.; KLAY, W.E. Forecasting State sales tax revenues: comparing the accuracy of different methods. **State & Local Government Review**, v. 26, n. 3, p. 142-152, 2007. Disponível em: <<http://www.jstor.org/stable/4355099>>. Acesso em: 12 mar. 2010.

GUARAGNA, P.; MELLO, M. Um modelo de previsão de arrecadação do ICMS. **Estudos Econômicos-Fiscais**. Sefaz-RS. Disponível em: <<http://www.sefaz.rs.gov.br/ASP/Download/UmModeloPrevisaoArrecadacaoICMS.pdf>>. Acesso em: 20 mar. 2011.

HAMILTON, J. **Time series analysis**. Princeton University Press, Princeton, 1994.

HOFF, J.C. **A practical guide to Box-Jenkins forecasting**. California: Lifetime Learning Publications, 1983.

JARQUE, C.M.; BERA, A.K. Efficient tests for normality, homocedasticity and serial independence of regression residuals. **Economics Letters**, v. 6, n. 3, p. 255-259, 1980.

JOHNSTON, Jack; DINARDO, John. **Econometric Methods**. 4. ed. McGraw Hill, New York, (International Student Edition), 1997.

KIM, I.; MADDALA, G.S. **Unit root, cointegration and structural change**. Themes in Modern Econometrics. Cambridge-USA, 1998.

KIRCHGASSNER, G.; WOLTERS, J. **Introduction to modern time series analysis**. Springer: New York, 2007.

KONG, D. (2003). **Taxable sales forecasting**: a case of econometric modeling for the 58 counties of California, USMikesell, J. (1999). Fiscal Administration: analysis and applications for the public sector. Fort Worth, TX: Harcourt Brace.

KONG, D. Local Government revenue forecasting: the California County experience. **Journal of Public Budgeting, Accounting & Financial Management**, 2007. Disponível em: <<http://www.allbusiness.com/government>>. Acesso em: 23 abr. 2010.

KWIATKOWSKI, D.; PHILLIPS, P.C.B.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationary against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.

LEHMANN, E.L.; CASELLA, G. **Theory of point estimation**. 2. ed. New York: Springer, 1998.

LIEBEL, M. J. **Previsão de Receitas Tributárias**: O Caso do ICMS no Estado do Paraná. Mestrado Universidade Federal do Rio Grande do Sul, 2004.

LIEBEL, M.J.; FOGLIATTO F.S. Método para previsão de receita tributária. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 25., 2005, Porto Alegre. **Anais...** Porto Alegre: ENEGEP, 2005.

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

LUTKEPOHL, H.; KRATZIG, M. **Applied time series econometrics**. Cambridge University Press: New York, 2004.

MADDALA, G.S. **Introdução à econometria**. 3. ed. Rio de Janeiro: LTC, 2003.

_____. **Introduction to econometrics**. 2. ed. Macmillan: New York, 1992.

MARQUES C.F.A.; UCHOA, C.A.G. Estimac o e previs o do ICMS na Bahia. II **Encontro de Economia Baiana**. Set. 2006.

MEDEIROS NETO, J.S. **Tributos cumulativos**. Consultoria Legislativa da C mara dos Deputados. Dispon vel em: <<http://www2.camara.gov.br/documentos-e-pesquisa/publicacoes/estnottec/tema20/pdf/108559.pdf>>. Acesso em: 20 mar. 2012.

MONTGOMERY, D.C.; JENNINGS, C.L.; KULAHCI, M. **Introduction to analysis time series and forecasting**. New Jersey: Wiley and Sons, 2008.

NERNOVE, M.; GREYTER, D.M.; CARVALHO, J.L. **Analysis of economic time series**: a synthesis. Revisited Edition. San Diego: Academic Press, 1995.

NELSON, C.R.; PLOSSER, G.J. Trends and random walks in macroeconomics time series. **Journal of Monetary Economics**, v. 10, n. 2, p. 139-162, 1982.

PANKRATZ, Alan. **Forecasting with univariate Box-Jenkins models**. New York: Wiley, 1983.

PASSOS, J.J.; RAMOS, E.M.L.S.; ALMEIDA, S.S. **Utilização de modelos ARIMA para previsão da arrecadação de ICMS do estado do Pará**. Disponível em: <<http://www.ufpa.br/abe/programacao/resumos/com-jairopasso2.pdf>>. Acesso em: 4 set. 2011.

PECEGUINI, E.E. **Análise comparativa de métodos de previsão aplicados à arrecadação do ICMS** - Estado de São Paulo. Brasília: ESAF, 2001.

PIANCASTELLI, M.; PEROBELLI, F. ICMS: **Evolução recente e guerra fiscal**. Instituto de Pesquisa Econômica Aplicada (IPEA), 1996. (Texto para Discussão n. 402).

PHILLIPS, P.C.B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, p. 335-346, 1988.

SAMOHYL, R.W.; SILVA, V.W.; DANTAS, B.A. **A utilização da metodologia Box & Jenkins na previsão de curto prazo do ICMS do Estado de Santa Catarina**. 2000.

SANTOS, A.V.; COSTA, J.H.F. Análise de modelos de séries temporais para a previsão mensal do ICMS do estado do Maranhão para o ano de 2008. **Cadernos IMESC 6**, São Luís, 2008.

SILVEIRA, P.A.C.V. **Direito tributário e análise econômica do Direito: uma visão crítica**. Rio de Janeiro: Elsevier, 2008.

SIQUEIRA, M.L. **Modelos de séries temporais para a previsão da arrecadação tributária federal**. 205f. Dissertação (Mestrado em Economia), Universidade Federal de Pernambuco, 2002.

SPANOS, A. **Statistical foundations of econometric modeling**. Cambridge: Cambridge University of Press, 1986.

SCHWARZ, G. Estimating the dimensional of a model. **Annals of Statistics**, Hayward, v. 6, n. 2, p. 461-464, 1978.

STOCK, J.H.; WATSON, M.W. **Econometria**. São Paulo: Addison Wesley, 2004.

STOCK, J.H. **Forecasting economica times series**. Econometria. São Paulo: Addison Wesley, 1999.

TSAY, R.S. **Analysis of financial times series**. 3. ed. New Jersey: John Wiley and Sons, 2010.

VANDAELE, W. **Applied time series and Box-Jenkins models**. United Kingdom: Academic Press, 1983.

VARSANO, R. **A evolução do sistema tributário brasileiro ao longo do século: anotações e reflexões para futuras reformas**. Brasília: IPEA, 1996. (Texto para Discussão n. 405).

WEI, William W.S. **Time series analysis, univariate and multivariate methods**. 2. ed. Addison-Wesley Publishing Company, 2006.

APÊNDICES

APÊNDICE A - Resultados dos testes de raiz unitária para a série do ICMS da Bahia

ADF-BA											
Tendência e Constante				Constante				Sem regressores			
Nível (ADF3)		DIF(ADF3)		Nível ADF(2)		DIF ADF(2)		Nível ADF(1)		DIF ADF(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-8.079	0.000	-19.159	0.000	-0.261	0.927	-19.197	0.000	2.345	0.996	-18.813	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010	1%	-4.010	1%	-3.467	1%	-3.467	1%	-2.578	1%	-2.578	1%
-3.435	5%	-3.435	5%	-2.878	5%	-2.878	5%	-1.943	5%	-1.943	5%
-3.142	10%	-3.142	10%	-2.575	10%	-2.575	10%	-1.616	10%	-1.616	10%
PP-BA											
Tendência e Constante				Constante				Sem regressores			
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)		Nível PP(1)		DIF PP(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-7.130	0.000	-25.457	0.000	-0.878	0.794	-25.567	0.000	2.501	0.997	-19.825	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010143	1%	-4.01044	1%	-3.466994	1%	-3.467205	1%	-2.577945	1%	-2.578018	1%
-3.435125	5%	-3.435269	5%	-2.877544	5%	-2.877636	5%	-1.942614	5%	-1.942624	5%
-3.141565	10%	-3.141649	10%	-2.575381	10%	-2.57543	10%	-1.615522	10%	-1.615515	10%
KPSS-BA											
Tendência e Constante				Constante							
Nível		1a. Diferença		Nível		1a. Diferença					
Estatística LM		Estatística LM		Estatística LM		Estatística LM					
0.344815		0.027661		1.711082		0.026416					
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos					
0.216	1%	0.216	1%	0.739	1%	0.739	1%				
0.146	5%	0.146	5%	0.463	5%	0.463	5%				
0.119	10%	0.119	10%	0.347	10%	0.347	10%				

Quadro 01 - Resultados dos testes de raiz unitária para a série do ICMS do Estado da Bahia

Fonte: Dados da pesquisa.

**APÊNDICE B - Resultados dos testes de raiz unitária para a série do
ICMS do Amazonas**

ADF-AM											
Tendência e Constante				Constante				Sem regressores			
Nível (ADF3)		DIF(ADF3)		Nível ADF(2)		DIF ADF(2)		Nível ADF(1)		DIF ADF(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-5.789	0.000	-16.567	0.000	-0.369	0.911	-16.590	0.000	1.666	0.977	-16.419	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010	1%	-4.010	1%	-4.010	1%	-3.467	1%	-2.578	1%	-2.578	1%
-3.435	5%	-3.435	5%	-3.435	5%	-2.878	5%	-1.943	5%	-1.943	5%
-3.142	10%	-3.142	10%	-3.142	10%	-2.575	10%	-1.616	10%	-1.616	10%
PP-AM											
Tendência e Constante				Constante				Sem regressores			
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)		Nível PP(1)		DIF PP(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-5.6551	0.000	-22.694	0.000	0.12734	0.967	-22.702	0.000	3.09113	0.9995	-17.634	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010	1%	-4.010	1%	-3.467	1%	-3.467	1%	-2.578	1%	-2.578	1%
-3.435	5%	-3.435	5%	-2.878	5%	-2.878	5%	-1.943	5%	-1.943	5%
-3.142	10%	-3.142	10%	-2.575	10%	-2.575	10%	-1.616	10%	-1.616	10%
KPSS-AM											
Tendência e Constante				Constante							
Nível		1a. Diferença		Nível		1a. Diferença					
Estatística LM		Estatística LM		Estatística LM		Estatística LM					
0.096943		0.117998		1.705355		0.203081					
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos					
0.000	1%	0.216	1%	0.739	1%	0.739	1%				
0.000	5%	0.146	5%	0.463	5%	0.463	5%				
0.000	10%	0.119	10%	0.347	10%	0.347	10%				

Quadro 2 - Resultados dos testes de raiz unitária para a série do ICMS do Estado do Amazonas
Fonte: Dados da pesquisa.

**APÊNDICE C - Resultados dos testes de raiz unitário para a série do
ICMS de São Paulo**

ADF-SP											
Tendência e Constante				Constante				Sem regressores			
Nível (ADF3)		DIF(ADF3)		Nível ADF(2)		DIF ADF(2)		Nível ADF(1)		DIF ADF(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-8.079	0.000	-19.159	0.000	-0.261	0.927	-19.197	0.000	2.345	0.996	-18.813	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010	1%	-4.010	1%	-3.467	1%	-3.467	1%	-2.578	1%	-2.578	1%
-3.435	5%	-3.435	5%	-2.878	5%	-2.878	5%	-1.943	5%	-1.943	5%
-3.142	10%	-3.142	10%	-2.575	10%	-2.575	10%	-1.616	10%	-1.616	10%
PP-SP											
Tendência e Constante				Constante				Sem regressores			
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)		Nível PP(1)		DIF PP(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-8.060	0.000	-38.533	0.000	0.541	0.988	-35.410	0.000	6.071	1.000	-20.863	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.0101	1%	-4.0104	1%	-3.467	1%	-3.4672	1%	-2.5779	1%	-2.578	1%
-3.4351	5%	-3.4353	5%	-2.8775	5%	-2.8776	5%	-1.9426	5%	-1.9426	5%
-3.1416	10%	-3.1416	10%	-2.5754	10%	-2.5754	10%	-1.6155	10%	-1.6155	10%
KPSS-SP											
Tendência e Constante				Constante							
Nível		1a. Diferença		Nível		1a. Diferença					
Estatística LM		Estatística LM		Estatística LM		Estatística LM					
0.101763		0.12302		1.729583		0.300725					
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos					
0.216	1%	0.216	1%	0.739	1%	0.739	1%				
0.146	5%	0.146	5%	0.463	5%	0.463	5%				
0.119	10%	0.119	10%	0.347	10%	0.347	10%				

Quadro 3 - Resultados dos testes de raiz unitária para a série do ICMS do Estado de São Paulo
Fonte: Dados da pesquisa.

**APÊNDICE D - Resultados dos testes de raiz unitária para a série do
ICMS do RioGrande do Sul**

ADF-RS											
Tendência e Constante				Constante				Sem regressores			
Nível (ADF3)		DIF(ADF3)		Nível ADF(2)		DIF ADF(2)		Nível ADF(1)		DIF ADF(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-8.387	0.000	-9.022	0.000	-0.684	0.847	-9.028	0.000	3.087	1.000	-14.089	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.010	1%	-4.014	1%	-3.469	1%	-3.469	1%	-2.578	1%	-2.578	1%
-3.435	5%	-3.437	5%	-2.879	5%	-2.879	5%	-1.943	5%	-1.943	5%
-3.142	10%	-3.143	10%	-2.576	10%	-2.576	10%	-1.615	10%	-1.616	10%
PP-RS											
Tendência e Constante				Constante				Sem regressores			
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)		Nível PP(1)		DIF PP(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-8.8765	0.000	-94.783	0.0001	-0.8677	0.7966	-94.747	0.0001	6.3788	1.000	-22.316	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.0101	1%	-4.0104	1%	-3.467	1%	-3.4672	1%	-2.5779	1%	-2.578	1%
-3.4351	5%	-3.4353	5%	-2.8775	5%	-2.8776	5%	-1.9426	5%	-1.9426	5%
-3.1416	10%	-3.1416	10%	-2.5754	10%	-2.5754	10%	-1.6155	10%	-1.6155	10%
KPSS-RS											
Tendência e Constante				Constante							
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)					
Estatística LM		Estatística LM		Estatística LM		Estatística LM					
0.298663		0.154065		1.716059		0.155919					
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos					
0.216	1%	0.216	1%	0.739	1%	0.739	1%				
0.146	5%	0.146	5%	0.463	5%	0.463	5%				
0.119	10%	0.119	10%	0.347	10%	0.347	10%				

Quadro 4 - Resultados dos testes de raiz unitária para a série do ICMS do Estado do Rio Grande do Sul

Fonte: Dados da pesquisa.

**APÊNDICE E - Resultados dos testes de raiz unitário para a série do
ICMS de Goiás**

ADF-GO											
Tendência e Constante				Constante				Sem regressores			
Nível (ADF3)		DIF(ADF3)		Nível ADF(2)		DIF ADF(2)		Nível ADF(1)		DIF ADF(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-4.3694	0.0031	-12.28	0.000	0.25087	0.975	-12.299	0.000	3.66034	0.9999	-15.069	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.0107	1%	-4.011	1%	-3.4676	1%	-3.4676	1%	-2.5782	1%	-2.5781	1%
-3.4354	5%	-3.4356	5%	-2.8778	5%	-2.8778	5%	-1.9426	5%	-1.9426	5%
-3.1417	10%	-3.1418	10%	-2.5755	10%	-2.5755	10%	-1.6155	10%	-1.6155	10%
PP-GO											
Tendência e Constante				Constante				Sem regressores			
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)		Nível PP(1)		DIF PP(1)	
t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor	t	P-valor
-10.436	0.000	-32.31	0.0001	0.50074	0.9864	-32.152	0.0001	3.35753	0.9998	-23.216	0.000
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos	
-4.0101	1%	-4.0104	1%	-3.467	1%	-3.4672	1%	-2.5779	1%	-2.578	1%
-3.4351	5%	-3.4353	5%	-2.8775	5%	-2.8776	5%	-1.9426	5%	-1.9426	5%
-3.1416	10%	-3.1416	10%	-2.5754	10%	-2.5754	10%	-1.6155	10%	-1.6155	10%
KPSS-GO											
Tendência e Constante				Constante							
Nível (PP3)		DIF(PP3)		Nível PP(2)		DIF PP(2)					
Estatística LM		Estatística LM		Estatística LM		Estatística LM					
0.153197		0.084753		1.720351		0.201779					
Valores Críticos		Valores Críticos		Valores Críticos		Valores Críticos					
0.216	1%	0.216	1%	0.739	1%	0.739	1%				
0.146	5%	0.146	5%	0.463	5%	0.463	5%				
0.119	10%	0.119	10%	0.347	10%	0.347	10%				

Quadro 5 - Resultados dos testes de raiz unitária para a série do ICMS do Estado de Goiás
Fonte: Dados da pesquisa.

APÊNDICE F - PREVISÃO GOIÁS 2011

Tabela 1 - Parâmetros do modelo de previsão estimado de Goiás

Valores em bilhões (R\$)			
OUTLIERS	PARÂMETRO ESTIMADO	ERRO-PADRÃO	T
AO2006DEZ	-0,4331	0,07297	-5,93532
ARIMA (3,1,0)			
AR(1)	-0,6899	0,07534	-9,15715
AR(2)	-0,4378	0,08589	-5,09722
AR(3)	-0,2229	0,07532	-2,95937
C	0,0105	0,0029	3,62069
Variância	0,006686		

Fonte: dados da pesquisa.

Tabela 2 - Previsão da arrecadação do ICMS de Goiás para o ano de 2011

Valores em bilhões (R\$)						
DATA	OBSERVADO	BANDA INFERIOR	PREVISÃO	BANDA SUPERIOR	ERRO	ERRO(%)
JAN/11	0,83	0,60	0,71	0,83	0,12	14,82%
FEV/11	0,83	0,61	0,72	0,85	0,11	13,07%
MAR/11	0,79	0,61	0,73	0,87	0,06	7,66%
ABR/11	0,70	0,61	0,74	0,89	-0,03	-4,85%
MAI/11	0,71	0,60	0,74	0,91	-0,03	-4,20%
JUN/11	0,79	0,60	0,75	0,93	0,04	4,60%
JUL/11	0,76	0,60	0,76	0,96	0,00	0,45%
AGO/11	0,80	0,60	0,77	0,98	0,03	3,75%
SET/11	0,80	0,60	0,78	1,00	0,02	3,12%
OUT/11	0,78	0,60	0,78	1,02	0,00	-0,40%
NOV/11	0,77	0,60	0,79	1,04	-0,03	-3,36%
DEZ/11	1,31	0,61	0,80	1,06	0,51	38,99%
TOTAL	9,88	-	9,07	-	0,81	8,16%

Fonte: Elaborado pelo autor




Figura 1– Previsão ICMS – GO 2011

Fonte: Elaborado pelo autor.

APÊNDICE G - PREVISÃO RIO GRANDE DO SUL 2011

Tabela 3 - Parâmetros do modelo de previsão estimado do Estado do Rio Grande do Sul

OUTLIERS	PARÂMETRO ESTIMADO	ERRO-PADRÃO	T
AO2003JUN	0,2956	0,0726	4,07
SARIMA (0,1,2)(0,1,1)12			
MA(1)	0,7202	0,07208	9,992
MA(2)	-0,0328	0,07079	-0,463
SMA(12)	0,9924	0,04944	20,07
C	0,0000	0,00048	-0,030
Variância	0,0058199		

Fonte: Dados da pesquisa

Tabela 4 - Previsão da arrecadação do ICMS do Rio G. do Sul para o ano de 2011

Valores em bilhões (R\$)						
Data	Observado	Banda Inferior	Previsão	Banda Superior	Erro	Erro(%)
JAN/11	1,665	1,432	1,665	1,937	-0,001	-0,06%
FEV/11	1,434	1,253	1,467	1,717	-0,032	-2,26%
MAR/11	1,455	1,227	1,447	1,708	0,008	0,53%
ABR/11	1,643	1,335	1,587	1,888	0,055	3,36%
MAI/11	1,540	1,303	1,562	1,873	-0,023	-1,46%
JUN/11	1,525	1,324	1,601	1,934	-0,076	-4,96%
JUL/11	1,582	1,289	1,569	1,911	0,013	0,84%
AGO/11	1,686	1,311	1,608	1,973	0,077	4,58%
SET/11	1,637	1,361	1,682	2,080	-0,046	-2,78%
OUT/11	1,721	1,382	1,721	2,145	-0,001	-0,03%
NOV/11	1,793	1,422	1,786	2,242	0,008	0,42%
DEZ/11	1,823	1,468	1,857	2,349	-0,034	-1,85%
TOTAL	19,503	16,106	19,553	23,756	-0,051	-0,26%

Fonte: dados da pesquisa.




Figura 2 - Previsão ICMS-RS 2011

Fonte: Elaborado pelo autor

APÊNDICE H – PREVISÃO AMAZONAS 2011

Tabela 5 - Parâmetros do modelo de previsão estimado do Amazonas

OUTLIER	PARÂMETRO ESTIMADO	ERRO-PADRÃO	T
AO1999FEV	-0,2456	0,05659	1,81
LS2009JAN	-0,2473	0,06022	-4,33
SARIMA (0,1,0)(0,1,1)₁₂			
MA(1)	0,4525	0,06546	6,9126
SMA(12)	0,9991	0,05188	19,258
C	0,0013	0,0007	1,81
Variância	0,0041		

Fonte: Elaborado pelo autor.

Tabela 6 - Previsão da arrecadação do ICMS do Amazonas em 2011

Valores em bilhões (R\$)

DATA	OBSERVADO	BANDA INFERIOR	PREVISÃO	BANDA SUPERIOR	ERRO	ERRO %
JAN/11	0,469	0,406	0,467	0,537	0,003	0,55%
FEV/11	0,453	0,377	0,445	0,525	0,008	1,84%
MAR/11	0,457	0,346	0,418	0,505	0,039	8,62%
ABR/11	0,454	0,391	0,481	0,592	-0,027	-5,89%
MAI/11	0,482	0,396	0,497	0,623	-0,016	-3,22%
JUN/11	0,461	0,388	0,496	0,632	-0,034	-7,39%
JUL/11	0,495	0,392	0,509	0,660	-0,014	-2,91%
AGO/11	0,533	0,389	0,513	0,677	0,019	3,65%
SET/11	0,508	0,422	0,565	0,757	-0,057	-11,25%
OUT/11	0,504	0,418	0,569	0,774	-0,065	-12,94%
NOV/11	0,550	0,431	0,595	0,821	-0,045	-8,22%
DEZ/11	0,555	0,408	0,571	0,800	-0,016	-2,97%
TOTAL	5,920	4,764	6,125	7,902	-0,205	-3,46%

Fonte: Elaborado pelo autor.




Figura 3- Previsão do ICMS-AM 2011

Fonte: Elaborado pelo autor.

APÊNDICE I - PREVISÃO SÃO PAULO 2011

Tabela 7 - Parâmetros do modelo de previsão estimado de São Paulo

OUTLIER	PARÂMETRO ESTIMADO	ERRO-PADRÃO	T
AO1998.JUN	0,1438	0,0322	4,4700
AO2000.NOV	0,1369	0,0323	4,2400
AO2001.FEV	-0,1703	0,0322	-5,2900
AO2002.OUT	0,1437	0,0322	4,4600
AO2003.DEZ	0,1536	0,0323	4,7600
AO2006.MAR	0,1757	0,0322	5,4600
AO2006.NOV	0,1832	0,0323	5,6800
AO2009.JAN	-0,2551	0,0323	-7,8900
AO2010.JAN	-0,1516	0,0323	-4,6900
SARIMA (0,1,2)((0,1,1) ₁₂)			
MA(1)	0,3249	0,07319	4,439131
MA(2)	0,0767	0,07294	1,051549
SMA(12)	0,9941	0,04913	20,23407
C	0,0005	0,00044	1,12
Variância	0,001437		

Fonte: Elaborado pelo autor.

Tabela 8 - Previsão da arrecadação do ICMS de São Paulo para o ano de 2011

Valores em bilhões (R\$)

DATA	OBSERVADO	BANDA INFERIOR	PREVISÃO	BANDA SUPERIOR	ERRO	ERRO(%)
JAN/11	7,822	8,099	8,732	9,416	-0,911	-11,6%
FEV/11	7,890	7,301	8,001	8,767	-0,110	-1,4%
MAR/11	8,097	7,374	8,174	9,060	-0,077	-0,9%
ABR/11	8,352	7,760	8,693	9,739	-0,341	-4,1%
MAI/11	8,489	7,683	8,695	9,841	-0,206	-2,4%
JUN/11	8,384	7,801	8,915	10,189	-0,531	-6,3%
JUL/11	8,328	7,815	9,014	10,398	-0,686	-8,2%
AGO/11	8,623	7,870	9,161	10,663	-0,537	-6,2%
SET/11	8,941	8,155	9,577	11,246	-0,635	-7,1%
OUT/11	8,808	8,359	9,901	11,727	-1,093	-12,4%
NOV/11	8,678	8,172	9,761	11,660	-1,084	-12,5%
DEZ/11	9,726	8,317	10,015	12,061	-0,290	-3,0%
TOTAL	102,139	94,705	108,640	124,768	-6,501	-6,4%

Fonte: Elaborado pelo autor.




Figura 4-- Previsão do ICMS-SP para o ano de 2011

Fonte: Elaborado pelo autor.

APÊNDICE J - PREVISÃO BAHIA 2011

Tabela 9 - Parâmetros do modelo de previsão estimado da Bahia

OUTLIER	PARÂMETRO ESTIMADO	ERRO-PADRÃO	t
AO2000.AGO	0,2723	0,05641	4,827158
AO2005.SET	0,2382	0,05642	4,221907
AO2006.SET	0,2287	0,05652	4,046355
AO2010.MAIO	0,2642	0,05741	4,601986
SARIMA (0,1,1)(0,1,1)₁₂			
MA(1)	0,5956	0,07586	
MA(2)	0,059	0,07535	
SMA(12)	0,8755	0,04599	
C	-0.0002	0,00047	-0,44
Variância	0,0040171		

Fonte: Elaborado pelo autor.

Tabela 10 - Previsão para o ICMS da Bahia para o ano de 2011

Valores em bilhões (R\$)

DATA	OBSERVADO	BANDA INFERIOR	PREVISÃO	BANDA SUPERIOR	ERRO	ERRO(%)
JAN/11	1,078	0,960	1,088	1,233	-0,010	-1,0%
FEV/11	1,004	0,909	1,042	1,193	-0,037	-3,7%
MAR/11	0,999	0,845	0,975	1,125	0,024	2,4%
ABR/11	1,072	0,922	1,072	1,247	-0,001	-0,1%
MAI/11	1,102	0,884	1,036	1,215	0,066	5,9%
JUN/11	1,095	0,898	1,059	1,249	0,036	3,3%
JUL/11	1,059	0,887	1,054	1,252	0,005	0,5%
AGO/11	1,180	0,900	1,076	1,287	0,104	8,8%
SET/11	1,130	0,923	1,112	1,340	0,017	1,5%
OUT/11	1,123	0,968	1,173	1,422	-0,050	-4,5%
NOV/11	1,138	0,927	1,132	1,381	0,007	0,6%
DEZ/11	1,228	0,947	1,163	1,429	0,065	5,3%
TOTAL	13,208	10,972	12,983	15,373	0,225	1,7%

Fonte: Elaborado pelo autor.




Figura 5- Previsão do ICMS-BA para o ano de 2011

Fonte: Elaborado pelo autor.

ANEXOS

ANEXO A – Arrecadação mensal do ICMS dos estados no período de janeiro de 1997 a dezembro de 2011

Valores nominais em milhões de reais					
Data	Amazonas	Bahia	Goiás	Rio G. do Sul	São Paulo
1997.01	110,32	219,79	127,57	322,40	2.000,90
1997.02	105,60	233,41	113,50	351,81	1.855,10
1997.03	97,16	187,62	126,00	322,78	1.733,53
1997.04	93,23	209,54	130,08	352,33	1.971,82
1997.05	116,78	201,59	126,35	361,11	1.909,58
1997.06	108,71	208,38	123,84	337,83	1.989,80
1997.07	114,09	215,58	133,74	315,28	2.013,89
1997.08	100,57	217,10	130,79	315,71	1.969,04
1997.09	99,26	212,86	163,24	315,18	2.005,19
1997.10	98,40	228,69	126,66	333,11	2.086,36
1997.11	102,00	220,77	124,00	334,09	2.001,74
1997.12	88,73	216,77	161,85	345,13	1.982,11
1998.01	83,99	237,42	129,44	374,15	1.962,55
1998.02	82,33	236,50	130,20	340,81	1.768,55
1998.03	69,51	216,09	121,80	303,43	1.868,61
1998.04	81,50	223,99	131,30	351,35	1.944,36
1998.05	87,35	218,75	126,98	354,26	1.960,67
1998.06	91,60	221,80	137,33	359,12	2.251,05
1998.07	87,62	226,13	135,44	348,97	1.940,95
1998.08	85,78	219,04	142,78	352,89	1.841,05
1998.09	88,44	223,03	125,19	353,53	2.003,86
1998.10	89,52	223,55	126,57	351,98	1.923,44
1998.11	96,83	237,79	126,44	382,45	1.914,15
1998.12	90,26	217,31	125,27	359,12	1.940,12
1999.01	86,70	245,32	138,36	398,32	1.988,99
1999.02	65,96	229,14	133,76	291,16	1.865,64
1999.03	80,01	253,40	124,09	367,52	1.907,93
1999.04	88,05	243,18	137,71	386,61	2.030,22
1999.05	85,95	225,67	161,90	354,52	1.945,60
1999.06	80,07	233,71	145,39	373,02	2.080,03
1999.07	87,43	250,52	154,89	402,51	2.113,88
1999.08	84,05	248,14	158,89	385,70	2.211,61
1999.09	107,58	252,81	193,19	418,74	2.262,34
1999.10	106,74	289,32	150,99	415,60	2.267,95
1999.11	118,08	286,82	168,81	425,34	2.250,29
1999.12	112,05	265,19	162,60	440,52	2.319,95

Continua

Continuação					
Data	Amazonas	Bahia	Goiás	Rio G. do Sul	São Paulo
2000.01	108,15	314,31	174,75	489,50	2.325,41
2000.02	101,78	288,55	151,34	422,74	2.142,20
2000.03	101,05	287,94	166,28	424,00	2.211,95
2000.04	103,84	289,51	172,37	452,11	2.371,40
2000.05	112,87	288,97	175,50	414,31	2.387,38
2000.06	114,08	283,99	187,53	463,34	2.437,48
2000.07	120,29	323,53	179,91	460,64	2.513,25
2000.08	115,68	397,56	185,09	473,26	2.804,12
2000.09	120,11	290,31	218,14	512,29	2.772,28
2000.10	130,61	342,82	195,64	493,03	2.860,44
2000.11	131,94	317,87	205,24	525,08	3.129,82
2000.12	144,04	338,62	186,34	516,51	2.663,14
2001.01	129,00	342,47	206,29	592,42	2.752,05
2001.02	125,66	342,20	201,33	515,39	2.246,98
2001.03	108,93	321,60	195,15	471,68	2.919,51
2001.04	145,78	362,74	205,09	573,03	2.790,14
2001.05	145,00	336,89	208,65	538,54	2.895,85
2001.06	137,11	363,98	216,88	524,05	2.899,08
2001.07	144,39	379,15	214,91	566,25	2.926,07
2001.08	150,07	335,03	230,23	530,29	2.820,18
2001.09	142,18	352,03	224,94	585,46	2.798,64
2001.10	140,31	372,70	219,97	566,77	2.956,98
2001.11	146,44	361,27	228,62	560,55	2.825,17
2001.12	141,08	372,48	263,21	681,94	2.862,64
2002.01	157,52	389,61	224,87	531,16	2.987,28
2002.02	147,46	390,11	222,13	589,75	2.604,73
2002.03	129,15	343,49	202,61	497,54	2.637,56
2002.04	152,77	384,75	247,52	617,18	3.002,13
2002.05	146,28	411,08	261,28	569,85	2.883,65
2002.06	152,72	390,96	235,92	590,01	2.968,55
2002.07	151,05	390,08	262,17	602,93	3.039,97
2002.08	162,40	447,04	259,64	611,25	3.008,00
2002.09	194,31	474,85	259,60	637,48	3.236,25
2002.10	182,23	542,52	254,32	624,67	3.971,39
2002.11	198,31	504,44	289,13	699,67	3.581,06
2002.12	176,56	484,96	301,27	870,00	3.333,60

Continua

Continuação

Data	Amazonas	Bahia	Goiás	Rio G. do Sul	São Paulo
2003.01	190,25	496,15	260,75	794,24	3.385,54
2003.02	173,66	497,57	296,61	702,85	3.222,08
2003.03	185,39	445,13	281,11	638,00	3.190,68
2003.04	190,19	489,39	335,92	601,81	3.247,46
2003.05	172,56	455,59	258,11	669,08	3.134,55
2003.06	180,86	465,12	319,73	921,92	3.147,56
2003.07	164,88	469,41	298,17	604,49	3.236,91
2003.08	183,12	471,60	302,88	680,06	3.190,35
2003.09	184,29	499,77	322,31	706,28	3.379,86
2003.10	184,81	510,07	342,30	768,73	3.459,85
2003.11	198,31	518,46	299,20	919,75	3.511,34
2003.12	185,18	553,10	381,63	981,66	4.183,21
2004.01	192,98	534,58	320,99	776,55	3.606,95
2004.02	182,52	487,10	269,30	741,21	3.291,27
2004.03	171,00	512,86	302,30	702,88	3.510,95
2004.04	198,55	679,65	315,85	684,90	3.697,71
2004.05	199,16	566,13	315,65	763,90	3.708,33
2004.06	211,55	564,73	336,79	732,15	3.875,06
2004.07	219,13	591,95	340,00	805,14	3.784,85
2004.08	219,13	610,59	392,49	826,94	3.960,95
2004.09	288,52	600,13	339,39	796,64	4.083,62
2004.10	236,01	696,39	316,23	875,86	4.053,68
2004.11	241,02	586,35	343,38	868,26	4.175,04
2004.12	253,07	702,35	385,73	1.063,52	4.174,07
2005.01	242,00	702,21	330,97	826,08	4.250,55
2005.02	225,22	574,43	337,07	781,15	3.918,42
2005.03	215,38	542,81	307,97	826,77	4.046,89
2005.04	233,96	596,50	328,69	921,34	4.223,44
2005.05	235,93	664,55	341,78	887,43	4.125,69
2005.06	242,68	689,37	338,95	931,81	4.190,10
2005.07	251,24	572,37	333,52	899,89	4.170,80
2005.08	248,30	585,62	357,37	930,89	4.231,37
2005.09	267,42	814,14	420,40	1.029,01	4.374,97
2005.10	278,30	690,86	384,43	1.247,69	4.409,78
2005.11	284,99	671,29	372,84	1.011,04	4.440,13
2005.12	277,00	726,70	369,71	1.089,84	4.619,13

Continua

Continuação

Data	Amazonas	Bahia	Goiás	Rio G. do Sul	São Paulo
2006.01	279,06	694,17	351,78	1.101,59	4.560,04
2006.02	262,51	674,88	430,15	894,00	3.742,53
2006.03	235,63	641,59	438,55	910,18	4.883,64
2006.04	270,46	676,30	249,08	952,41	4.539,46
2006.05	275,20	631,30	414,95	910,86	4.632,75
2006.06	276,28	660,59	351,81	1.043,20	4.576,97
2006.07	280,21	659,86	358,51	931,67	4.456,72
2006.08	276,49	680,92	385,55	903,04	4.583,45
2006.09	302,53	905,65	361,64	1.103,71	4.733,16
2006.10	305,35	831,09	334,65	1.055,11	5.474,83
2006.11	300,20	727,27	471,94	1.054,21	6.245,16
2006.12	295,71	820,56	550,01	953,31	5.359,73
2007.01	289,38	713,32	406,61	1.135,88	5.017,52
2007.02	272,16	695,44	389,46	901,74	4.732,81
2007.03	252,43	657,68	455,10	844,38	4.657,04
2007.04	307,88	741,94	424,50	988,60	4.969,82
2007.05	293,38	688,98	411,03	993,17	5.148,43
2007.06	312,98	740,41	439,66	1.013,39	5.088,50
2007.07	308,05	728,39	426,54	946,37	5.165,25
2007.08	296,54	766,25	442,76	1.031,51	5.303,07
2007.09	341,78	802,03	442,08	1.027,41	5.960,79
2007.10	350,59	780,65	458,31	1.045,61	5.735,31
2007.11	347,39	769,86	473,68	1.169,64	5.652,12
2007.12	339,50	855,68	461,25	1.160,00	5.761,73
2008.01	332,40	848,23	439,84	1.265,62	6.003,36
2008.02	347,91	913,16	447,07	1.138,74	5.588,42
2008.03	303,19	805,07	452,32	1.093,97	5.405,36
2008.04	341,21	814,95	474,14	1.200,88	6.017,92
2008.05	353,52	798,79	522,66	1.204,68	6.266,77
2008.06	347,54	886,81	565,20	1.357,24	6.427,04
2008.07	394,39	819,75	543,96	1.199,09	6.511,31
2008.08	386,56	910,10	565,89	1.172,82	6.582,34
2008.09	437,17	885,66	566,34	1.310,80	6.922,36
2008.10	472,53	888,59	518,67	1.320,17	7.414,26
2008.11	495,20	864,11	554,78	1.360,08	6.458,87
2008.12	407,99	803,35	492,52	1.201,07	6.723,59

Continua

Continuação					
Data	Amazonas	Bahia	Goiás	Rio G. do Sul	São Paulo
2009.01	343,47	825,10	505,64	1.342,78	5.278,89
2009.02	315,41	821,12	485,25	1.111,07	6.417,16
2009.03	279,71	732,13	479,41	1.116,24	6.034,54
2009.04	323,04	796,80	533,18	1.282,46	5.957,06
2009.05	389,19	857,05	569,29	1.249,67	6.097,19
2009.06	326,27	801,11	557,18	1.196,96	6.295,26
2009.07	322,31	833,33	582,48	1.176,31	6.474,67
2009.08	354,72	853,95	600,10	1.214,49	6.557,06
2009.09	392,63	892,57	583,01	1.243,15	6.875,51
2009.10	422,26	929,58	609,73	1.308,76	7.239,07
2009.11	460,42	926,41	610,59	1.419,09	7.216,06
2009.12	449,42	873,70	601,18	1.425,69	8.129,70
2010.01	397,27	1.034,07	643,98	1.541,03	6.732,90
2010.02	398,97	906,36	574,20	1.144,85	7.094,62
2010.03	368,27	883,33	672,33	1.421,60	7.353,55
2010.04	494,48	1.047,07	682,75	1.534,25	7.745,00
2010.05	488,85	1.239,98	745,99	1.452,97	7.363,32
2010.06	467,62	970,91	671,85	1.396,59	7.721,64
2010.07	477,42	952,09	683,79	1.456,08	7.615,06
2010.08	495,28	959,35	738,79	1.706,10	7.753,97
2010.09	507,95	1.032,99	662,76	1.542,51	7.918,73
2010.10	500,19	1.011,34	670,77	1.491,50	8.030,47
2010.11	483,21	1.019,72	713,07	1.580,38	8.128,68
2010.12	475,71	1.085,79	709,81	1.625,47	8.858,84
2011.01	469,24	1.077,81	832,03	1.664,51	7.821,82
2011.02	452,89	1.004,34	826,92	1.434,28	7.890,36
2011.03	457,40	999,25	791,52	1.455,13	8.097,17
2011.04	454,00	1.071,63	702,22	1.642,54	8.352,33
2011.05	481,52	1.101,72	713,10	1.539,68	8.489,19
2011.06	461,41	1.095,29	787,89	1.524,88	8.383,97
2011.07	494,51	1.058,54	763,50	1.582,32	8.328,43
2011.08	532,81	1.180,22	797,58	1.685,54	8.623,46
2011.09	507,95	1.129,55	800,66	1.636,92	8.941,30
2011.10	503,81	1.123,24	780,91	1.720,89	8.807,70
2011.11	549,61	1.138,48	766,57	1.793,23	8.677,64
2011.12	554,73	1.228,24	1.312,28	1.823,01	9.725,57

Quadro 1 - Dados da arrecadação do ICMS mensal dos Estados

Fonte: Elaborado pelo autor.

Nota: Dados disponíveis em: <<http://www.fazenda.gov.br/confaz/boletim>>. Acesso em: 12/032012.