



**UNIVERSIDADE FEDERAL DO CEARÁ – UFC
CURSO DE PÓS-GRADUAÇÃO EM ECONOMIA – CAEN
MESTRADO PROFISSIONAL – MPE**

JOSÉ RIBAMAR PEREIRA

**PREVISÃO DE RECEITA DO ISSQN DE TERESINA:
UMA ABORDAGEM COM SÉRIES TEMPORAIS**

**FORTALEZA
2007**

JOSÉ RIBAMAR PEREIRA

**PREVISÃO DE RECEITA DO ISSQN DE TERESINA:
UMA ABORDAGEM COM SÉRIES TEMPORAIS**

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

Orientador: Prof. Dr. Paulo de Melo Jorge Neto

FORTALEZA

2007

P493c

Pereira, José Ribamar

Previsão de receita do ISSQN de Teresina: uma abordagem com séries temporais. José Ribamar Pereira. 2007.

63f.

Orientador: Prof. Dr. Paulo de Melo Jorge Neto.

Dissertação (Mestrado Profissional): Universidade Federal do Ceará – Curso de pós-graduação em Economia – CAEN, Fortaleza, 2007.

1. Econometria. 2. Tributos. 3. Previsão ISSQN.

I. Título.

CDD - 336

JOSÉ RIBAMAR PEREIRA

**PREVISÃO DE RECEITA DO ISSQN DE TERESINA:
UMA ABORDAGEM COM SÉRIES TEMPORAIS**

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

Aprovada em 19 / 12 / 2007.

BANCA EXAMINADORA:

Prof. Dr. Paulo de Melo Jorge Neto
Orientador

Prof. Dr. Ronaldo Albuquerque e Arraes
Membro da Comissão Examinadora

Prof. Dr. Roberto Tatiwa Ferreira
Membro da Comissão Examinadora

Aos meus pais, Pedro Gonçalves e Joana Lima, que me ensinaram a encontrar no saber o caminho para uma vida melhor.

AGRADECIMENTOS

À Prefeitura de Teresina e Fundação CEPRO que disponibilizaram os dados para servir de base ao estudo.

Aos Professores do CAEN, especialmente ao Prof. Dr. Paulo Neto pela orientação e paciência com minhas limitações e ansiedade para concluir este ciclo de estudo.

Ao Prof. Dr. Ronaldo Arraes pela maestria na condução da turma do MPE-2006, Parnaíba-PI.

Ao pessoal do Ipeplan pelo suporte oferecido para funcionamento da nossa turma.

Aos amigos Cristóvão, Eulálio, Sebastião, Leandro, Henry Portela e Antonio Luís pelos esclarecimentos vitais para a elaboração deste estudo.

Às minhas filhas, Nara e Clarissa, por compreenderem a ausência de um pai que estuda e trabalha.

À minha inseparável companheira Myrtes Oliveira, no papel de protetora dos meus sonhos, especialmente concluir o Mestrado em Economia do CAEN.

O determinismo não é um pré-requisito necessário para que uma ciência possa fazer previsões (Karl Popper)

RESUMO

Neste estudo, pretende-se determinar um modelo de previsão mensal de curto prazo para a receita de ISSQN de Teresina. Para evidenciar este propósito servirão de suporte matemático os modelos VAR e Box-Jenkins, a partir de séries históricas concernentes ao período de janeiro de 2002 a dezembro de 2006. Após a estimação dos modelos, propõe-se um diagnóstico para mensurar a capacidade inicialmente preditiva. Dentre os modelos manipulados temos o SARIMA (12,1,1)(0,0,12) o qual antecipadamente demonstrou ser mais robusto em relação ao modelo VAR. Oportunamente à discussão de outras nuances internas ou à margem do trabalho, conclui-se que, o modelo com séries temporais, em função de sua capacidade preditiva, pode se transformar em um instrumental consistente com vistas ao incremento da arrecadação do ISSQN da Prefeitura de Teresina.

Palavras-chave: Imposto sobre serviços de qualquer natureza; modelo var; modelos Box-Jenkins; previsão.

ABSTRACT

In this study, It is intended to determine a short-run monthly forecasting model for the ISSQN of Teresina city. In order for this purpose to be clear, the models VAR and Box-Jenkins will be of mathematical support, from historical series concerning the period of January 2002 to December 2006. After the estimation of the models, it is proposed a diagnosis to measure the initially predictive capacity. Among the models manipulated, we have SARIMA (12,1,1)(0,0,12), which has resulted most robust in advance concerning the VAR model. Propitiously to other internal or marginal nuances to the study, it is concluded, preliminarily, that the time series model due to its predictive capacity can become a consistent instrument targeting at the augment of the ISSQN collecting of Teresina City Administration.

Keywords: Municipal service tax of any nature; var model; box-jenkins models; forecasting.

LISTA DE GRÁFICOS

GRÁFICO 1	Participação mensal do ISSQN na arrecadação (2002 – 2006)	19
GRÁFICO 2	Arrecadação mensal do ISSQN (2002 – 2006)	19
GRAFICO 3	Receita prevista x realizada – ISSQN (2006)	20
GRAFICO 4	Arrecadação do ISSQN por atividade – 2006 (350 maiores contribuintes)	20
GRÁFICO 5	Valores previstos x realizados – modelo VAR em diferença	41
GRÁFICO 6	Correlograma dos resíduos de estimação	42
GRÁFICO 7	Valores previstos x realizados - SARIMA(12,1,1)(0,0,12) em diferença	44
GRÁFICO 8	Previsão SARIMA(12,1,1)(0,0,12) em diferença	45
GRÁFICO 9	Correlograma de resíduos SARIMA (12,1,1) (0,0,12)	63

LISTA DE TABELAS

TABELA 1	Propriedades da FAC e da FACP	52
TABELA 2	Teste ADF para Ltranspass	52
TABELA 3	Teste ADF para Lconsuener	53
TABELA 4	Teste ERS para Larrecissr	54
TABELA 5	Teste ERS para Lfistribut	54
TABELA 6	Critério de seleção de Lags de Schwarz	55
TABELA 7	Estimação Modelo VAR em diferença	56
TABELA 8	Resultados da Estimação Modelo VAR	57
TABELA 9	Estimação Modelo SARIMA (3,1,3) (12,0,12) com dummy	58
TABELA 10	Estimação Modelo SARIMA (3,1,3) (12,0,12) sem dummy	59
TABELA 11	Estimação Modelo SARIMA (2,1,3) (12,0,12)	60
TABELA 12	Estimação Modelo SARIMA (1,1,1) (12,0,12)	61
TABELA 13	Estimação Modelo SARIMA (12,1,1) (0,0,12)	62
TABELA 14	Critério de informação de Schwarz	62
TABELA 15	Avaliação da capacidade preditiva dos modelos	63
TABELA 16	Comparativo realizado x previsto ISSQN (Período jul-out./2006)	63

LISTA DE SIGLAS

ADF Dickey Fuller Aumentado

AIC Critério de Informação de Akaike

ARIMA Auto-regressivo Integrado de Média Móvel

BIC Critério de Informação Bayesiana de Schwarz

DMS Declaração Mensal de Serviços

EAM Erro Absoluto Médio

EPAM Erro Percentual Absoluto Médio

FAC Função de Autocorrelação

FACP Função de Autocorrelação Parcial

ICMS Imposto Sobre Circulação de Mercadorias e Serviços

ISSQN Imposto Sobre Serviços de Qualquer Natureza

LDO Lei de Diretrizes Orçamentárias

LOA Lei de Orçamento Anual

PMT Prefeitura Municipal de Teresina

PPA Plano Plurianual

SARIMA Sazonal Auto-regressivo de média móvel

SPF Sistema de Planejamento Fiscal

VAR Vetor Auto-regressivo

SUMÁRIO

LISTA DE GRÁFICOS	
LISTA DE TABELAS	
LISTA DE SIGLAS	
INTRODUÇÃO	12
1. IMPOSTO SOBRE SERVIÇOS DE QUALQUER NATUREZA	15
1.1 Aspectos legais	15
1.2 Características do ISSQN	17
2. ASPECTOS METODOLÓGICOS	22
2.1 Análises de séries temporais	23
2.1.1 Modelo auto-regressivo de média móvel (ARMA)	28
2.1.2 Modelo auto-regressivo integrado de média móvel (ARIMA)	29
2.1.3 Modelos sazonais	29
2.2 Metodologia Box-Jenkins	31
2.3 Performance preditiva dos modelos	34
2.4 Metodologia vetorial auto-regressiva - VAR	35
2.4.1 Propriedades básicas de modelos – VAR	37
2.4.2 Identificação do Sistema VAR-Padrão	37
3. RESULTADOS E DISCUSSÕES	39
3.1 Análise do modelo VAR	40
3.2 Análise do modelo Box-Jenkins	42
3.2.1 Previsão do modelo SARIMA (12,1,1)(0,0,12)	45
3.3 Comparação dos modelos de previsão	45
CONCLUSÃO	47
BIBLIOGRAFIA	49
ANEXOS	51

INTRODUÇÃO

A estabilização econômica implantada através do Plano Real, dentre muitos efeitos econômico-administrativos, resgatou a importância do planejamento orçamentário e financeiro: em decorrência da queda dos índices de inflação, o imposto inflacionário, que financiava grande parte dos gastos públicos em nosso país, foi drasticamente reduzido, gerando um déficit nas contas governamentais.

A rigor, os gestores públicos passaram a utilizar um instrumental técnico na etapa correspondente à realização das receitas fundamentado em expectativas, *a priori*, em variáveis como índice de preços e crescimento econômico da economia.

Apesar do rigor objetivo naturalmente característico de todo instrumental matemático, duas teses paradoxalmente seminais podem ser feitas: a primeira, que não temos garantia da confirmação dessas expectativas; e a segunda, de que não existem evidências empíricas igualmente necessárias ao grau de importância das principais variáveis explicativas das evoluções das receitas.

No entanto, pragmaticamente, não me guiarei, aliás, excluirei o problema, porque proponho um estudo que tem como finalidade a construção de um modelo de previsão de arrecadação do ISSQN para a Prefeitura de Teresina utilizando séries temporais, especialmente o modelo VAR e a abordagem de Box-Jenkins.

Dois são os motivos particulares ao assunto: primeiro, pela falta constatável de um mecanismo que subsidie os gestores públicos uma vez que as técnicas gerenciais utilizadas até então para a previsão de receitas públicas são pouco avançadas, resultando em baixo grau de acurácia preditiva. No caso de Teresina existe um agravante ainda maior, a prefeitura não adota nenhum modelo econométrico para operacionalizar as previsões de sua arrecadação, sendo calculada, até então, apenas intuitivamente. Seria como ignorar o trabalho de uma instituição especializada na previsão do tempo pela primazia de supostos palpites pouco científicos. Que tal então especular com mais chances de acertos? Que tal por a discussão no campo do provável e refutar o meramente possível?. Está em jogo muito mais que um modo particular de ver as coisas, trata-se da melhor maneira de “trabalhar” com o dinheiro público.

Optamos pelo ISSQN, eis o segundo motivo, por ser a principal fonte de receita tributária própria de Teresina proveniente do setor de serviços que dispõe de uma elevada taxa de crescimento e de potencial de cobrança. Em 2005, por exemplo, obteve um incremento de 18,97%, representando 38% do total das receitas próprias do município de acordo com dados constantes do Relatório de Atividades da Prefeitura de Teresina, do referido ano.

Em decorrência do aumento demonstrado e da importância do imposto em âmbito municipal, propomos uma análise mais aprimorada que indique severidade na estimação de futuros índices, sobretudo que corrija prováveis danos à economia, pela baixa arrecadação, mas que, por outro lado, evite que isso ocorra. Não vejo outra forma mais cientificamente segura de viabilizar esses intentos se não através de um modelo de Previsão de Receita do Imposto Sobre Serviços de Qualquer Natureza-ISSQN de Teresina a partir de uma abordagem com séries temporais.

O trabalho está estruturado da seguinte forma: o primeiro capítulo trata dos aspectos legais da Receita Pública e onde abordamos as peças que compõem o sistema orçamentário - Plano Plurianual (PPA), a Lei de Diretrizes Orçamentárias (LDO) e a Lei de Orçamento Anual (LOA)-, e descreve as características do ISSQN de Teresina. Ademais, apresenta a evolução da arrecadação e previsão mensal, em percentuais, no período 2002 a 2006 por meio comparativo entre a receita prevista e a realizada deste período. Por fim, expõe os setores de atividades com maior peso na arrecadação, particularmente no exercício de 2006.

No segundo capítulo, evidenciamos alguns trabalhos relevantes publicados sobre previsão de impostos e relatamos a fundamentação teórica de suporte para previsão com séries temporais através do modelo VAR e da abordagem de Box-Jenkins.

No terceiro capítulo, analisamos os resultados empíricos apresentados para cada modelo em discussão. Em seguida, fazemos uma avaliação geral e comparação para indicar aquele com melhor capacidade preditiva.

Por fim, concluo que a previsão de receita do ISSQN de Teresina, através de modelos com séries temporais, obtém um melhor desempenho preditivo, constatado

pela estatística do erro quadrático médio-EQM. Podendo, ser adotado como instrumental para incrementar a arrecadação do ISSQN de Teresina.

1 IMPOSTO SOBRE SERVIÇOS DE QUALQUER NATUREZA

1.1 Aspectos Legais

Etimologicamente, a Receita Pública corresponde ao recolhimento efetuado para o erário através de numerário ou espécie de bem que representa valor. Ela poderia advir tanto de direitos legais de recebimentos como ser obtida para objetivo específico, podendo pertencer ou não ao ente público (PECEGUINI, 2001).

De acordo com a Lei nº 4.320, de 17 de março de 1964, a Receita Pública pode ser enquadrada tanto na categoria orçamentária como extra-orçamentária. No primeiro caso, têm-se as receitas que se encontram no orçamento e, adicionalmente, os valores das operações de crédito já validadas em Lei. No segundo caso, encontram-se as receitas correspondentes a meras entradas compensatórias. Essa Lei dispõe sobre a classificação econômica da Receita Pública, destacando-se neste estudo o ISSQN, integrante das Receitas Correntes.

Para que as fontes de receita sejam efetivamente materializadas nos cofres públicos, as gestões fazendárias dos entes federativos devem seguir determinadas etapas. A primeira seria a da previsão da receita. A segunda, a de lançamento ou declaração do valor a ser recolhido. E, a terceira, a da arrecadação e recolhimento.

Muitas vezes, a estimativa a ser feita no primeiro passo é entendida como o valor potencial a ser arrecadado pelos cofres públicos. No entanto, os conceitos de previsão e de potencial de arrecadação são distintos. Somente em uma situação ideal é que eles indicariam os mesmos valores.

Isso se verifica, pois, o potencial de arrecadação pode ser compreendido como o montante ideal de arrecadação, correspondente ao que seria alcançado caso não houvesse inadimplência, sonegação e elisão fiscal, por exemplo. Para ser determinado esse potencial, seria necessária a definição de variáveis como o PIB tributável e as alíquotas efetivas, que são de difícil avaliação. Já a previsão das receitas deve ser compreendida como uma expectativa do montante a ser efetivamente recolhido pelos cofres públicos.

Para determinar a expectativa, estima-se a arrecadação futura por intermédio de técnicas a serem aplicadas à série histórica de uma receita específica (PECEGUINI, 2001).

A primeira etapa de realização das receitas ganhou, a partir de meados da década de 1990, importância crescente no planejamento fazendário, reforçada pela Lei Complementar nº 101, de 04 de maio de 2000. A conhecida Lei de Responsabilidade Fiscal teve sua concepção relacionada ao processo de descentralização do Estado Brasileiro, no qual os governos locais ganharam autonomia tanto na obtenção de recursos como na definição de como estes seriam aplicados (AFONSO, ARAÚJO e FERREIRA, 2002).

No que se refere ao planejamento, um dos princípios ressaltados pela referida Lei foi de que os municípios terão de adotar controles mais apurados sobre suas receitas e cobrar os tributos que sejam de sua competência constitucional, efetuar previsões e acompanhar a evolução entre realizado e projetado (OLIVEIRA, 2000).

Nesse aspecto, merece destaque o artigo 12, da Lei Complementar nº 101, especialmente em seu parágrafo 3º:

“§ 3º: O Poder Executivo de cada ente colocará à disposição dos demais Poderes e do Ministério Público, no mínimo trinta dias antes do prazo final para encaminhamento de suas propostas orçamentárias, os estudos e as estimativas das receitas para o exercício subsequente, inclusive da receita corrente líquida, e as respectivas memórias de cálculo”.

Uma das peças que integra o planejamento fiscal de cada esfera governamental é o sistema orçamentário. Este guarda correspondência com o planejamento efetivado por particulares, posto que, com maior ou menor rigor, os indivíduos também determinam as suas receitas e, com isto, estabelecem suas prioridades de atendimento (BASTOS, 2001).

De acordo com a legislação atual, portanto, três peças compõem o sistema orçamentário: o Plano Plurianual (PPA); a Lei de Diretrizes Orçamentárias (LDO); e a Lei de Orçamento anual (LOA). Dentre estas, o Decreto-lei nº 200/67 somente não previa a elaboração de um plano que fizesse referência à LDO, criada na Constituição de 1988.

A importância da previsão da arrecadação não se esgota em si mesma. A Lei Complementar nº 101/01 determina que o chefe do poder executivo passe a ser obrigado a prestar contas periodicamente. Dentre os itens que têm de ser avaliados, o art. 58 estatui a análise do desempenho da arrecadação efetiva em relação à previsão.

A etapa da previsão das receitas orçamentárias deve, portanto, buscar o menor erro possível. Neste sentido, dois pontos devem ser considerados. Primeiro, a possibilidade de se verificar erro na previsão é razoável, posto que as estimativas inseridas na LOA devem ser feitas com meses de antecedência do próximo exercício financeiro. Segundo, e diante da possibilidade não desprezível de erro, a previsão das receitas deve ser conservadora, pois desta forma se evitará que seja fixado um montante de gastos públicos superior ao total de recursos esperados (PECEGUINI, 2001).

1.2 Características do ISSQN

Existem três aspectos fundamentais do tributo. Primeiro, trata-se de um instrumento utilizado pela administração pública para obter ingressos que servem para cobrir as suas despesas quando estas não podem ser atendidas por seu patrimônio. Segundo, a competência de sua cobrança é privativa do Estado. Terceiro, sua arrecadação deve estar atrelada à satisfação dos encargos públicos orçamentários.

Nesse contexto, os tributos de competência própria são uma das principais origens de recursos para os municípios brasileiros. Para Bastos (2001), a possibilidade de vir a instituí-los providencia um pilar de sustentação à Federação, posto que possibilita uma relativa autonomia econômica e financeira para os entes federativos.

O CTN, em seu art. 16, define imposto como sendo: “O tributo cuja obrigação tem por fato gerador uma situação independente de qualquer atividade estatal específica, relativa ao contribuinte”.

Eles podem ser, de acordo com a sua base econômica, divididos em três grandes categorias. A primeira seria a dos impostos sobre a riqueza ou patrimônio.

A segunda, a dos impostos sobre a renda. Enquanto que a terceira, a dos impostos sobre vendas de mercadorias e serviços (REZENDE, 2001).

De acordo com a Constituição Federal/88 em seu Art. 156, compete aos municípios instituir impostos sobre:

“I- propriedade predial e territorial urbana;

II- transmissão inter vivos, a qualquer título, por ato oneroso, de bens imóveis, por natureza ou acessão física, e de direitos reais sobre imóveis, exceto os de garantia, bem como cessão de direitos a sua aquisição;

III- serviços de qualquer natureza, não compreendido no art. 155, II, definidos em lei complementar.”

De acordo com o inciso III do art. 156 da Constituição Federal/88, a instituição do ISS por parte dos municípios deve observar determinados requisitos. A primeira condição é que estes entes da federação não podem cobrar o Imposto sobre os serviços que se encontram sujeitos à cobrança do Imposto sobre a Circulação de Mercadorias e Serviços (ICMS).

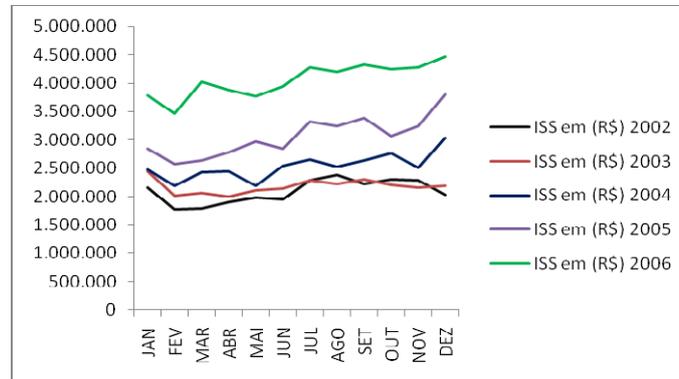
O ISSQN é um imposto que onera o consumo, tal como o ICMS, o Imposto sobre Produtos Industrializados (IPI), as contribuições sociais para o financiamento da seguridade social (Cofins e PIS-PASEP), o Imposto sobre Importação e o Imposto sobre Operações Financeiras (IOF) (Rezende, 2001).

No caso dos municípios, é o componente mais relevante na estrutura das receitas tributárias próprias municipais, representando em média 40% desta. Isto se deve em grande parte ao fato de que é o setor de serviços o que apresenta maiores taxas de crescimento no Brasil, além de possuir o maior potencial de cobrança.

A Prefeitura de Teresina fez previsão mensal de arrecadação do ISSQN¹, em percentuais, no período 2002 a 2006, onde a menor margem obtida representa 7,01, em fevereiro de 2005; e a maior, 10,35, em dezembro do mesmo ano, na forma expressa pelo gráfico 1 a seguir.

¹ Dados fornecidos pelo Setor de Fiscalização Tributária

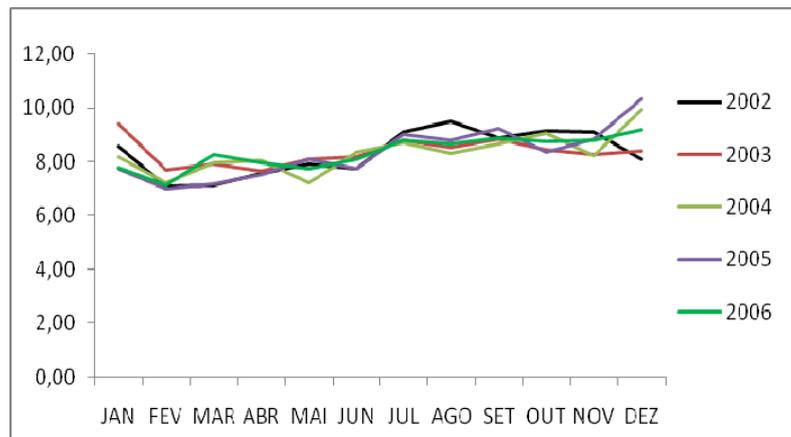
Gráfico 1: Participação mensal do ISSQN na arrecadação (2002 – 2006)



Fonte: Prefeitura de Teresina

No mesmo período, o gráfico 2 abaixo demonstra que PMT acompanhou a evolução da arrecadação mensal do ISSQN, em valores nominais.

Gráfico 2: Arrecadação mensal do ISSQN (2002 – 2006)

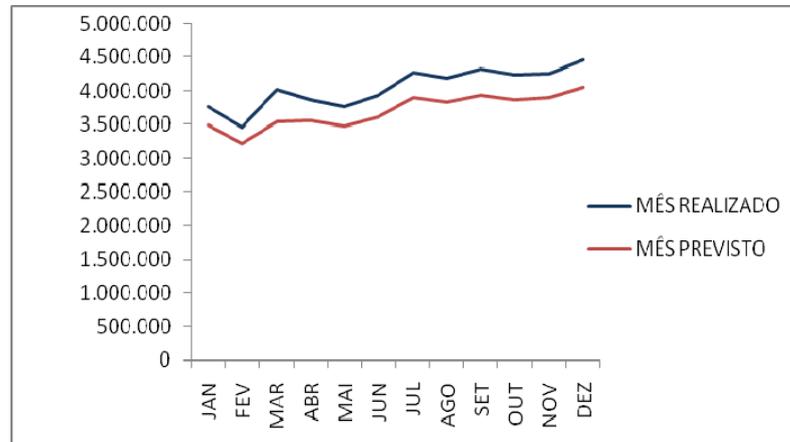


Fonte: Prefeitura de Teresina

Constatou-se que, ao longo do ano, existe um pico sazonal em dezembro, podendo ser justificado pelo aquecimento da atividade econômica, especialmente no setor de serviços. Já o mês de fevereiro sugere como variável explicativa o menor número de dias.

Também, quando se comparou a receita prevista com a realizada, em valores nominais (ano 2006) verificou-se a menor margem de erro, 7,12%, foi verificada em fevereiro. Em dezembro a maior, 9,19%.

Gráfico 3: Receita prevista x realizada – ISSQN (2006)

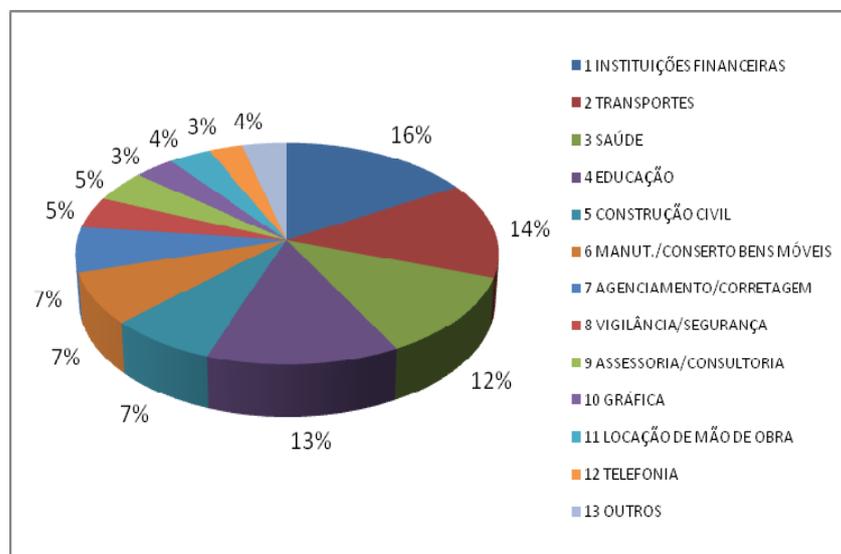


Fonte: Prefeitura de Teresina

Vale ressaltar que esses dados foram extraídos do Balancete da Prefeitura de Teresina, que considera os valores de acordo com o mês de competência.

Para identificar aquelas atividades com maior participação na arrecadação do ISS1, a Prefeitura fez um levantamento em 2006, e constatou que as instituições financeiras, com 16%, são as mais representativas na arrecadação, seguida por transportes, 14%, e saúde, 12% respectivamente.

Gráfico 4: Arrecadação do ISSQN por atividade – 2006 (350 maiores contribuintes)



Fonte: Prefeitura de Teresina

Com o intuito de monitorar essas atividades, foi implementado o Sistema ISS ON LINE, em fevereiro de 2004, que consiste num programa que obriga o prestador e o tomador de serviços estabelecidos em Teresina a enviar mensalmente à Prefeitura uma Declaração Mensal de Serviços-DMS, com informações sobre as atividades desenvolvidas pelo contribuinte. Essa medida pode sugerir a existência de uma quebra estrutural a partir de fevereiro daquele ano.

Em seguida, fora criado o Sistema de Planejamento Fiscal-SPF, que cruzaria informações dos contribuintes para reduzir o índice de sonegação do ISSQN. Por último, fora intensificada a Ação de Cobrança, durante o ano de 2006, favorecendo o incremento da arrecadação do ISSQN.

Apesar de todo esforço empreendido pela administração municipal, ela ainda não adota nenhum modelo econométrico para prever a arrecadação de suas receitas tributárias, razão pela qual propõe-se um estudo com séries temporais que venha subsidiar a Prefeitura com o objetivo de incrementar suas receitas.

2. ASPECTOS METODOLÓGICOS

Este capítulo tem como objetivo comentar alguns trabalhos publicados na área de previsão de arrecadação de impostos, especialmente do ISSQN, além de descrever o suporte conceitual e metodológico utilizado no estudo de séries temporais, com as abordagens de Box-Jenkins e a vetorial auto-regressiva - VAR.

Estudos de finanças públicas e política fiscal no Brasil têm produzido um grande número de trabalhos que requer uma análise criteriosa para saber que contribuição merece ser aceita ou não. Entretanto, quando o objetivo é ajustar especificações econométricas *strictu sensu* aos dados das receitas do setor público a literatura torna-se restrita, afirmam Santos e Ribeiro (IPEA, 2006).

Na dissertação de Ferreira (1996), é adotada uma combinação de modelos de Alisamento Exponencial, ARIMA (1.0,4) com a Função de Transferência para prever o ICMS mensal do estado do Ceará, período de janeiro a junho de 1995. Nessa combinação, obtém-se um erro percentual absoluto médio-EPAM, de 5,8% para previsão *ex-post*. Enquanto o EPAM do ARIMA resulta num valor de 5,9%. Numa demonstração de que a técnica de combinar modelos melhora a performance preditiva através da redução do erro médio.

Em pesquisa realizada por Castelar e Arraes (1996), sobre modelos para previsão das finanças do estado do Ceará, o ICMS e o FPE são enfatizados. Os autores combinam modelos ARIMA (1,0,4), Alisamento Exponencial e Função de Transferência para prever o ICMS mensal na forma agregada e desagregada.

Na primeira combinação, relativa ao período de janeiro a junho de 1995, resulta num EPAM de 4,8%, por conseguinte, uma boa predição. Na segunda combinação, a ausência de dados para o final do período de 1995 prejudica o desempenho do modelo.

Em estudo sobre a previsão do ICMS do estado de São Paulo, Perceguini (2001) compara os métodos: convencional, linha de tendência, série de tempo-decomposição clássica e autoregressivo. Como também utiliza o período de jan/00 a dez/00 para fazer a previsão e constata que o método séries de tempo-decomposição clássica obtém o melhor desempenho. O autor observa um EPAM de

4,6% para o período anual, sem desconsiderar o efeito da anistia concedida pelo Governo do Estado. Quando analisa o período semestral, ou seja, os seis primeiros meses de 2000, o método proporciona um EPAM de 0,5%.

Perceguini (2001) compara essa técnica com a modelagem de regressão e SARIMA (0,1,1)(0,1,1) para prever o Imposto de Renda, período de abril a junho de 2000. Nessa última, o erro quadrático médio – EQM, registra valor menor que a metade daquele, através do método dos indicadores. Isso pode explicar a inadequabilidade da técnica adotada pelo Poder Público.

Caldart (2006) utiliza dados de séries temporais para estimar um ARI(13,1,0) na previsão da receita mensal do ISS da cidade de Caxias do Sul(RS). Quando compara valores previstos com realizados, de maio a agosto de 2005, resulta num erro médio de -0,65%, o que confirma a boa capacidade preditiva do modelo para o curto prazo.

Embora existam estudos avançados nessa área, a Receita Federal e em sua maioria, Estados e Municípios adotam, segundo Melo (2001), o método dos indicadores para previsão da receita pública.

2.1. Análise de séries temporais

Este estudo trata de séries temporais, que vêm a ser qualquer conjunto de observações ordenadas no tempo. Para Maddalla (2003), a análise de uma única série de dados observados no tempo chama-se análise de séries temporais univariadas, enquanto a análise de inúmeras séries distintas é denominada de multivariada.

Atualmente, em virtude do desenvolvimento de novos instrumentos econométricos, o estudo de séries temporais parte do pressuposto de que a série é gerada integralmente por um mecanismo aleatório, ou seja, um processo estocástico, segundo o qual, em cada instante de tempo t , existem diferentes valores que a série pode assumir, para os quais estão associadas probabilidades de ocorrência.

Assim, um processo estocástico é definido como uma seqüência (no tempo) de variáveis aleatórias dispostas num mesmo espaço de probabilidade, razão por

que a descrição de seu comportamento futuro não pode ser feita por uma função determinística e, sim, apenas, probabilística.

Sob esse enfoque de análise, Gujarati (2000) afirma que, a partir de uma amostra de dados, também chamada de realização particular do processo estocástico, procura-se encontrar o modelo que se aproxima do processo gerador da série.

Como a estimativa do processo gerador da série é feita a partir do conjunto concreto de dados observados nos diferentes períodos de tempo, exige-se, para tanto, que o processo estocástico seja estacionário, pois somente é possível obter uma única observação em cada momento do tempo.

A estacionariedade de uma série temporal constitui uma pré-condição para a formulação de modelos autorregressivos ARIMA, afirmam Morettin e Tolo (2004).

Para que um processo estocástico seja francamente estacionário, requer o atendimento das condições abaixo:

$$1^a) \text{ Média: } E(Y_t) = \mu ; \quad (1)$$

$$2^a) \text{ Variância: } \text{Var}(Y_t) = E[(Y_t - \mu)^2] = \gamma_0 = \sigma^2 ; \quad (2)$$

$$3^a) \text{ Dependência linear: } \text{Cov}(Y_t, Y_{t-k}) = E[(Y_t - \mu)(Y_{t-k} - \mu)] = \gamma_k, k = 1, 2, \dots \quad (3)$$

Ou seja, se uma série for estacionária, sua média (a) e sua variância (b) variam apenas em relação à distância (k) que separa as duas observações consideradas.

A presença de raiz unitária em uma série temporal faz com que esta seja tratada como uma série temporal de caminho aleatório. E o caminho aleatório é um exemplo de série temporal não-estacionária (GUJARATI, 2000).

A finalidade de aplicação do teste de raiz unitária é a verificação da ordem de integração do processo gerador da série temporal Y_t . O número de diferenças necessárias para tornar a série original estacionária deriva, exatamente, da quantidade de raízes que se encontram sobre o círculo unitário, daí a denominação do teste (VASCONCELLOS e ALVES, 2000).

De acordo com Enders (1995), o teste de Dickey-Fuller se mostra relevante pois a inspeção da função de autocorrelação serve somente como indicador inicial da presença da tendência na série. Um decaimento lento da função de autocorrelação (FAC) poderia ser compreendido como um primeiro “sinal” de presença da raiz unitária.

Apesar deste indicativo, a distinção entre séries temporais estacionárias e não-estacionárias seria bastante imprecisa pela análise única do correlograma. Isto se daria, principalmente, nos casos em que a raiz não fosse unitária mas apresentasse valor próximo à unidade. O Dickey-Fuller aparece, então, como um teste formal para a constatação, ou não, desta raiz.

Nesse contexto, o teste foi ampliado para ADF. Enders (1995) afirma que, em função do não conhecimento do verdadeiro processo gerador, a defasagem na qual deve ser aplicado o teste ADF é desconhecida. Para a definição desta, dois aspectos devem ser, então, ponderados.

O primeiro é o fato de que a inclusão de diversos lags reduz o poder do teste de rejeitar a hipótese nula de raiz unitária, posto que se perdem graus de liberdade em função do número adicional de parâmetros a serem estimados e em razão da redução do número de observações pela aplicação de maior defasagem. Já o segundo aspecto seria o fato de que um número diminuto de lags pode não capturar o processo de geração de erros.

A ponderação destes dois aspectos passa pelo cálculo dos critérios de Akaike (AIC) e Schwarz (BIC) para um conjunto possível de modelos. A defasagem escolhida seria aquela que apresentasse os menores valores para estes critérios.

Cabe frisar que a inclusão apropriada dos regressores determinísticos para o teste de raiz unitária nunca será conhecida com certeza absoluta. No entanto, deve-se levar em consideração que a incorporação de menos ou mais regressores que o número apropriado pode fazer com que o teste da presença da raiz unitária deixe ser confiável. Para isto ser evitado é necessário o cumprimento das seguintes etapas: a primeira seria iniciar com o modelo menos restrito (que inclui tendência e intercepto), e aplicar o teste ADF na defasagem definida pelos critérios AIC e BIC.

Se a hipótese de raiz unitária for rejeitada, conclui-se que Y_t é estacionária. Caso contrário, parte-se para a segunda etapa.

Nesta, faz-se necessário determinar se foram incluídos muitos regressores determinísticos na primeira etapa. Testa-se, então, a significância do coeficiente da tendência (τ_{pt}), e, se este for significativo, a série temporal tem raiz unitária, caso contrário, retira-se este coeficiente e se cumpre a terceira etapa.

Nesta, estima-se a equação sem tendência e com intercepto. Se a hipótese nula for rejeitada, a série Y_t é estacionária. Caso não seja rejeitada, testa-se a significância do coeficiente do intercepto τ_{μ} . Caso o coeficiente seja significativo, a série Y_t tem raiz unitária. Se o coeficiente do intercepto não for significativamente diferente de zero, estima-se a equação sem o coeficiente do intercepto.

Na quarta e última etapa, aplica-se o teste ADF no modelo mais restrito (sem tendência e sem intercepto). Sendo a hipótese nula rejeitada, determina-se que Y_t não contém raiz unitária. Caso a hipótese nula não seja rejeitada, conclui-se que a série temporal Y_t é não-estacionária.

Para se identificar a correta especificação do modelo, faz-se necessário levar em consideração a qualidade do ajuste dos dados. Se, por um lado, lags adicionais dos componentes autoregressivos e/ou de médias móveis ocasionam redução da soma dos quadrados dos resíduos estimados, por outro, esta inclusão promove tanto a estimação de outros coeficientes, com perda de graus de liberdade, como a redução da performance da previsão do modelo ajustado (ENDERS, 1995).

Diante desta dificuldade da etapa de identificação do modelo, procurou-se adotar critérios de seleção de modelos que buscam responder ao dilema entre reduzir a soma dos quadrados dos resíduos com modelos que sejam os mais parcimoniosos.

Os dois critérios mais comuns são o Akaike Information Criterion (AIC) e o Schwarz Bayesian Criterion (BIC):

$$AIC = \ln \sigma_e^2 + \frac{2(p-q)}{n} \quad (4)$$

$$BIC = \ln \hat{\sigma}_\varepsilon^2 + \frac{(p+q) \ln(n)}{n} \quad (5)$$

Três componentes levados em consideração: a variância estimada de ε_t ; o tamanho da amostra n ; e os valores das defasagens p e q . Ao se comparar dois modelos, A e B, A será melhor ajustado que o modelo B, caso os valores dos critérios AIC e/ou BIC forem inferiores aos do modelo B.

Um instrumental utilizado para verificar a qualidade do modelo estimado é a análise dos resíduos deste modelo. Caso este esteja corretamente especificado, os resíduos devem comportar-se como ruído branco. Em particular, seus coeficientes de autocorrelação devem ser estatisticamente iguais a zero, posto que a dinâmica dos dados já deve ter sido capturada pelo modelo (VASCONCELLOS e ALVES, 2000).

Para testar a existência da autocorrelação residual, podem ser feitos testes individuais ou testes conjuntos para os coeficientes de autocorrelação $r_k(\hat{\varepsilon})$. De acordo com Enders (1995), para amostras que não sejam pequenas ou médias o teste conjunto apresenta melhor performance, o que o torna recomendável. Para se fazer este teste conjunto, utiliza-se o instrumental da estatística Q de Ljung-Box:

$$Q(k) = n(n+2) \sum_{k=1}^k \frac{r_k^2(\hat{\varepsilon})}{n-k} \quad (6)$$

$Q(k)$ em distribuição χ^2 com $k - p - q$ graus de liberdade.

Os valores da estatística Q devem ser comparados aos valores críticos da tabela da distribuição qui-quadrado (χ^2) a um determinado nível de significância. Sendo o valor de Q maior que o valor crítico, rejeita-se a hipótese de que as correlações não são significantes. Neste caso, rejeitar esta hipótese significa aceitar a alternativa de que pelo menos uma autocorrelação não é igual a zero.

Cabe salientar que o valor de k deve ser pelo menos igual à raiz quadrada do número de observações da amostra (CRIBARI-NETO, 2000). Convém lembrar, também, que a aplicação do teste Q não invalida a análise complementar do gráfico dos resíduos, para verificar a hipótese de variância residual constante ao longo do tempo (VASCONCELLOS e ALVES, 2000).

2.1.1 Modelo auto-regressivo de média móvel (ARMA)

Considera que a série temporal Y_t é em função de seus valores históricos e pelos termos aleatórios correntes e passados. Em sua versão mais simples, este modelo é definido como:

$$Y_t = \phi Y_{t-1} + \varepsilon_t - \theta \varepsilon_{t-1} \quad (7)$$

Sua variância é encontrada por:

$$\gamma_0 = \frac{(1+\theta^2-2\phi\theta)\sigma_\varepsilon^2}{1-\phi^2} \quad (8)$$

Através da equação de Y_t , percebe-se que para a série ser estacionária apenas respeitada a condição $|\phi| < 1$. Para que o ARMA(1,1) seja invertível, o módulo de θ deve ser menor que 1 ($|\theta| < 1$). As autocovariâncias deste modelo são encontradas por:

$$\gamma_1 = \phi\gamma_0 - \theta\sigma_\varepsilon^2 = \frac{(1-\phi\theta)(\phi-\theta)}{1-\phi^2}\sigma_\varepsilon^2 \quad (9)$$

$$\gamma_k = \phi\gamma_{k-1}, \text{ para } k \geq 2$$

A especificação genérica de um ARMA(p,q) é:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (10)$$

Mediante o operador de defasagem, a equação de Y_t pode ser escrita como:

$$\begin{aligned} Y_t &= (\phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p) Y_t + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \\ (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \\ \phi(B) Y_t &= \theta(B) \varepsilon_t \end{aligned} \quad (11)$$

Para que um ARMA(p,q) seja um processo estacionário e invertível, todas as raízes de $\phi(B) = 0$ e de $\theta(B) = 0$ devem cair fora do círculo unitário.

2.1.2 Modelo auto-regressivo integrado de média móvel (ARIMA)

Quando a série temporal analisada não observar a condição de estacionaridade, devem aplicar diferenças até que esta condição se torne válida. O número de diferenças necessárias é denominado ordem de integração (I).

Se Y_t é estacionária após ser diferenciada d vezes, com a série derivada deste processo podendo ser descrita como um modelo ARMA (p,q), diz-se que a série temporal Y_t segue um modelo ARIMA(p,d,q), podendo este ser representado por:

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (12)$$

Se $W_t = \Delta^d Y_t$

Utilizando o operador de defasagem B, a equação de Y_t pode ser reescrita como:

$$\begin{aligned} (1 - \phi_1 B - \dots - \phi_p B^p) W_t &= (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t \\ (1 - B)^d \phi(B) Y_t &= \theta(B) \varepsilon_t \end{aligned} \quad (13)$$

Se $W_t = (1 - B)^d Y_t$

Note que no modelo ARIMA (p,d,q), o polinômio $(1 - B)^d \phi(B) = 0$ apresenta d raízes sobre o círculo unitário e p raízes fora do círculo unitário.

2.1.3. Modelos sazonais

Caso as séries analisadas apresentem dados históricos mensais ou trimestrais, por exemplo, ganha importância a observância da correlação serial entre períodos de tempo distantes entre si, ao longo do ano, por s períodos, sendo s o número de observações verificadas neste período (ou seja, $s=12$ para dados mensais; $s=4$, para dados trimestrais).

Isto se mostra relevante no caso da arrecadação do ISSQN na cidade de Teresina. Em janeiro, por exemplo, a receita tende a apresentar o pico de arrecadação em função do aquecimento da atividade do setor de serviços em

dezembro. A correlação entre as receitas dos meses de janeiro deve ser alta, superando a verificada entre os meses de janeiro e fevereiro.

Nesse contexto é que se deve compreender a utilização dos modelos SARIMA. Esta classe de modelagem possibilita que se captem as correlações entre instantes de tempo t múltiplos de s .

Modelo sazonal auto-regressivo (SAR(P))

Este modelo corresponde à versão sazonal do AR(p):

$$\begin{aligned}
 Y_t &= \varphi_1 Y_{t-s} + \varphi_2 Y_{t-2s} + \dots + \varphi_p Y_{t-ps} + a_t \\
 (1 - \varphi_1 B^s - \varphi_2 B^{2s} - \dots - \varphi_p B^{ps}) Y_t &= a_t \\
 \varphi(B^s) Y_t &= a_t
 \end{aligned} \tag{14}$$

Modelo sazonal de média móvel (SMA(Q))

Este corresponde à versão sazonal do MA(q):

$$\begin{aligned}
 Y_t &= a_t - \theta_1 a_{t-s} - \theta_2 a_{t-2s} - \dots - \theta_Q a_{t-Qs} \\
 Y_t &= (1 - \theta_1 B^s - \theta_2 B^{2s} - \dots - \theta_Q B^{Qs}) a_t \\
 Y_t &= \theta(B^s) a_t
 \end{aligned} \tag{15}$$

Modelo sazonal auto-regressivo de média móvel (SARMA(P,Q))

Já este corresponde à versão sazonal do ARMA(p,q):

$$\begin{aligned}
 Y_t &= \varphi_1 Y_{t-s} + \varphi_2 Y_{t-2s} + \dots + \varphi_p Y_{t-ps} + a_t - \theta_1 a_{t-s} - \dots - \theta_Q a_{t-Qs} \\
 (1 - \varphi_1 B^s - \varphi_2 B^{2s} - \dots - \varphi_p B^{ps}) Y_t &= (1 - \theta_1 B^s - \dots - \theta_Q B^{Qs}) a_t \\
 \varphi(B^s) Y_t &= \theta(B^s) a_t
 \end{aligned} \tag{16}$$

Modelo sazonal auto-regressivo integrado de média móvel (SARIMA(P,D,Q))

O SARIMA(P,D,Q) se aplica a séries originais não estacionárias, que após D diferenças sazonais podem ser descritas por um processo estocástico sazonal estacionário SARMA(P,Q). Generalizando, este modelo pode ser escrito como:

$$W_t = \varphi_1 W_{t-s} + \dots + \varphi_p W_{t-ps} + a_t - \theta_1 a_{t-s} - \dots - \theta_Q a_{t-Qs}$$

$$(1 - \varphi_1 B^s - \dots - \varphi_p B^{ps})W_t = (1 - \theta_1 B^s - \dots - \theta_q B^{qs})a_t$$

$$\varphi(B^s)(1 - B^s)^D = \theta(B^s)a_t \quad (17)$$

Sendo $W_t = \Delta^D Y_t$, e D a ordem de integração sazonal.

2.2 Metodologia Box-Jenkins

A metodologia Box-Jenkins objetiva determinar um modelo estocástico linear da classe ARIMA (ou SARIMA) que, por hipótese, tenha gerado a série temporal Y_t . Para esta determinação, quatro etapas iterativas devem ser cumpridas.

1ª etapa: identificação do modelo

De forma resumida, esta etapa consiste em identificar quais dos “filtros” AR, I e MA (e SAR, I e SMA) fazem parte do processo estocástico que gerou a série temporal Y_t , bem como identificar as suas respectivas ordens (Vasconcellos e Alves, 2000). Esta é a etapa mais complexa da metodologia, não havendo consenso em relação à melhor estratégia a ser usada.

De acordo com Enders (1995), deve-se, primeiro, analisar o “mapa” da série temporal Y_t e suas funções de autocorrelação (FAC) e de autocorrelação parcial (FACP). No caso da análise gráfica, “plotando-se” cada observação da seqüência Y_t contra t se obtêm informações relativas a *outliers*, valores perdidos e quebras estruturais. Além disso, a presença de tendência pronunciada ou a aparência de variância e média que não sejam constantes servem como indicativo da não estacionariedade da série. Esta primeira verificação deve ser complementada pela análise da FAC e da FACP.

O teste final da não-estacionariedade da série pode ser feito mediante o teste da raiz unitária aumentado de Dickey-Fuller (teste ADF). Para a aplicação deste, deve-se definir, primeiro, o número ótimo da defasagem temporal da série pelos critérios de Schwarz (BIC) e Akaike (AIC). Caso seja validada a hipótese de não-estacionariedade pelo teste ADF, a série temporal Y_t deve ser diferenciada quantas vezes forem necessárias, até que se torne estacionária.

Somente com a série temporal sendo estacionária é que se busca a seleção de valores de p , d , q (e P , D , Q , no caso da presença da sazonalidade). Para esta finalidade são utilizados, de novo, os instrumentais da FAC e da FACP.

2ª etapa: estimação do modelo

Considerando válida a condição de estacionaridade, e verificadas possíveis configurações de modelos na etapa da identificação, a etapa da estimação leva em consideração três aspectos: a parcimônia do modelo, as condições de estacionaridade e invertibilidade; e a qualidade do ajuste (ENDERS, 1995).

O aspecto da parcimônia considera que a incorporação de coeficientes adicionais se, por um lado, aumenta o grau de ajuste, por outro reduz os graus de liberdade. De acordo com Box-Jenkins (1970), modelos que sejam parcimoniosos geram melhores projeções que as configurações sobre parametrizadas. O objetivo, portanto, é se aproximar do verdadeiro processo gerador sem que, no entanto, simule-se o exato processo (Enders, 1995).

A abordagem de Box-Jenkins pressupõe que o modelo seja tanto estacionário como invertível. Do ponto de vista formal, Y_t é invertível se puder ser representado por um processo autoregressivo de ordem infinita ou convergente. Este aspecto é relevante, pois a FAC e a FACP pressupõem, de forma implícita, que a série em questão possa ser representada por um modelo autoregressivo.

Para verificar a qualidade do ajuste do modelo, utilizamos de forma complementar à FAC e à FACP, os critérios AIC e BIC. Estes critérios têm como principal atributo a “penalização” dos modelos com muitos parâmetros, escolhendo-se aqueles mais parcimoniosos (VASCONCELLOS e ALVES, 2000).

3ª etapa: diagnóstico do modelo

Para a verificação da correta especificação do modelo ARIMA (p,d,q) ou SARIMA(p,d,q)(P,D,Q), analisa-se o termo aleatório ε_t , que deve apresentar as propriedades de um ruído branco. Caso estas propriedades não sejam verificadas, reiniciamos a tentativa de seleção do modelo pela 1ª etapa, o que ressalta a característica iterativa desta metodologia (Gujarati, 2000).

Com este objetivo, a prática comum é “plotar” os resíduos para verificar a presença de *outliers* e evidenciar períodos em que o modelo não se ajusta bem aos dados. Nesse contexto, torna-se importante que os resíduos do modelo estimado não sejam serialmente correlacionados.

Para esta checagem, deve-se construir a FAC e a FACP destes resíduos. Feito isto, pode-se verificar pela estatística de Ljung-Box (estatística Q) se todas as autocorrelações residuais ou autocorrelações parciais são estatisticamente significantes.

De acordo com Enders (1995), não existe um nível de significância que possa ser considerado o “mais apropriado”. Dois pontos, porém, ajudam a definir se um modelo está bem ajustado: a presença de correlações residuais marginais que sejam significantes, e valores da estatística Q que sejam também significantes ao nível de 10%. Nessas circunstâncias, torna-se possível formular um modelo melhor ajustado.

Cabe ressaltar que o coeficiente de determinação R^2 não desempenha, para estas classes de modelos, o mesmo papel que na análise de regressões. Isto porque, para os modelos ARIMA e SARIMA, o R^2 se associa aos parâmetros e não à variância residual (VASCONCELLOS e ALVES, 2000).

4ª etapa: previsão

Estando o modelo identificado, estimado e diagnosticado, cumpre-se a etapa da previsão de valores futuros. Talvez o mais importante uso destas classes de modelos seja, exatamente, a previsão dos valores da seqüência Y_f .

As previsões de um modelo ARIMA(p,d,q) são não viesadas. Isto não significa, porém, que sejam acuradas. Em relação a este aspecto, deve-se ressaltar que a variância do erro de previsão é função crescente de j, sendo j o momento de previsão futura. Dessa forma, pode-se dizer que as previsões de curto prazo são mais confiáveis que as de longo prazo (Enders, 1995).

2.3 Performance preditiva dos modelos

Este estudo tem como objetivo realizar previsão de curto prazo do ISSQN de Teresina, através de séries temporais. Para mensurar o desempenho dos modelos especificados, faz-se necessário adotar pelo menos uma estatística para medir a proximidade entre os valores previstos e realizados, ou seja, que avalie seu poder preditivo.

Para isso, vários métodos são sugeridos na literatura, os quais utilizam comumente os erros de previsão, $\varepsilon_{t+h} = X_{t+h} - \hat{X}_t(h)$, em seus cálculos.

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

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

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

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

$$EAM = \frac{\sum_{t=1}^n |X_t - \hat{X}_t|}{n}$$

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

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

Os valores gerados por essas estatísticas dependem da escala na qual a variável explicativa é mensurada. Desse modo, são as mais adequadas como medidas relativas para comparar previsão de uma mesma série baseada em diferentes modelos.

Por esses critérios, quanto menor o valor da estatística melhor o poder de previsão do modelo.

2.4. Metodologia Vetorial auto-regressiva (VAR)

Em análise de regressão múltipla, as inter-relações entre variáveis econômicas geralmente exigem que os modelos sejam tratados pela técnica de equações simultâneas. Nesses modelos, as variáveis são referidas como endógenas, exógenas ou predeterminadas, e sua estimação exige alguns pressupostos, ou seja, existe alguma restrição para estimação de modelos com equações simultâneas.

A forma usual para solucionar o problema de identificação, em modelos de equações simultâneas, é incorporar variáveis predeterminadas em algumas equações e em outras não. Por essa razão, Sims (1980) considerou tal questão como subjetiva para solução do sistema. Defendeu a premissa de que todas as variáveis devem ser tratadas simultânea e simetricamente, não concordando com a solução que permite a determinação de causalidade *ad hoc*. Essa discussão levou à introdução de um novo método de abordagem de séries multivariadas, dando início à discussão do modelo de vetores auto-regressivos (VAR).

Além disso, Sims (1980) procurou tornar os modelos multiequacionais capazes de analisar as inter-relações entre variáveis macroeconômicas e seus efeitos a partir de “choques” que provocam ciclo na economia, isto é, esses modelos foram capazes de analisar a importância relativa de cada “surpresa” (ou inovações) sobre as variáveis do sistema macroeconômico. Essa abordagem empírica possibilita maior entendimento de como as variáveis macroeconômicas respondem a esses “choques”, simultaneamente.

Conforme Sims (1980), o ponto de partida para estudos de modelos multivariados é tratar todas as variáveis simetricamente. Para simplificar essa análise, um exemplo de sistema de equações com duas variáveis, as quais se assumem como interdependentes e estão relacionadas por uma memória autoregressiva (Enders, 1995a), isto é, a seqüência $\{Y_t\}$ é afetada pelo seu passado e pela seqüência $\{z_t\}$ e vice-versa. As equações, chamadas de primitivas, podem ser escritas da seguinte forma:

$$Y_t = \delta_{10} - \delta_{12}z_t + \gamma_{11}y_{t-1} + \gamma_{12}z_{t-1} + \varepsilon_{yt} \quad (18)$$

$$z_t = \delta_{20} - \delta_{21}y_t + \gamma_{21}y_{t-1} + \gamma_{22}z_{t-1} + \varepsilon_{zt} \quad t=0,1,2,3,\dots$$

Ressalta-se que ambas as séries tenham os ε_{it} ruído branco com variância constante e não-correlacionados. A estrutura do sistema indica relações simultâneas entre y_t e z_t , e o problema está na relação entre os choques ε_{yt} na equação de z_t e ε_{zt} na equação y_t , o que os torna relacionados com as variáveis explicativas (a técnica-padrão requer que os regressores sejam não-correlacionados com o termo de erro). Dessa forma, para estimação do método de mínimos quadrados, incorre-se em violação de pressupostos, que tornam os parâmetros estimados não-confiáveis.

Para tornar o sistema primitivo estimável pelo método tradicional de mínimos quadrados, o sistema pode apresentar forma reduzida. Em síntese, pode-se dizer que o maior problema do processo VAR é verificar se este sistema de equações permite recuperar o sistema primitivo, ou seja, se é possível identificar o modelo com equações simultâneas.

Também é demonstrável que a estimação de um VAR nesses moldes é igual a estimação por MQO de cada equação individualmente. Dessa forma, todos os testes de especificação e estabilidade se aplicam para cada equação do sistema.

Sejam duas variáveis: x_t e y_t . Um VAR com estas duas variáveis assume o seguinte formato:

$$\begin{aligned} Y_t &= \alpha + \beta_1 Y_{t-1} + \dots + \Phi_1 x_{t-1} + \dots + \varepsilon_t \\ x_t &= \alpha' + \beta_1' Y_{t-1} + \dots + \Phi_1' x_{t-1} + \dots + \varepsilon_t \end{aligned} \quad (19)$$

A única imposição feita é que o número de defasagens seja igual para todas as variáveis do modelo. A presença de raízes unitárias pode trazer os mesmos problemas que causava nas regressões simples. Dessa forma, recomenda-se trabalhar com as séries em diferenças.

2.4.1 Propriedades básicas de modelos VAR

O modelo expresso pela equação pode ser especificado e generalizado para um modelo VAR(p), ou um modelo VAR de ordem (p), da seguinte forma:

$$x_t = \mu + A_1 x_{t-1} + \dots + A_p x_{t-p} + \varepsilon_t \quad p=1,2,3,\dots \quad (20)$$

$$\varepsilon_{1t} = \left(\frac{\varepsilon_{1t} - b_{12}\varepsilon_{2t}}{1 - b_{12}b_{21}} \right) \quad \text{e} \quad \varepsilon_{2t} = \left(\frac{\varepsilon_{2t} - b_{21}\varepsilon_{1t}}{1 - b_{12}b_{21}} \right)$$

Sabendo que ε_{it} são processos de ruído branco, permitindo, então, que ε_{it} tenha média zero, variância constante e não sejam correlacionados.

$$E(\varepsilon_t) = E(B^{-1}\varepsilon_t) \quad (21)$$

Média: $E(\varepsilon_t) = 0$

$$E(\varepsilon_{1t})^2 = \frac{1}{[1 - b_{12}b_{21}]^2} [\sigma_{\varepsilon_1}^2 + b_{12}^2 \sigma_{\varepsilon_2}^2] \quad (22)$$

Assim, a variância de ε_{1t} é independente do tempo (t).

A autocovariância entre ε_{1t} e ε_{1t-1} é dada por $Cov(\varepsilon_{1t}, \varepsilon_{1t-1}) = 0$, isto é, os erros são independentes em relação ao tempo, o que os torna estacionários.

2.4.2 Identificação do Sistema VAR-Padrão

Enders (1995a) afirmou que o maior problema do processo VAR é a identificação. É necessário verificar se a partir do momento em que se passa do sistema primitivo para o sistema reduzido o número de incógnitas da equação primitiva será o mesmo que o número de incógnitas da equação da forma reduzida. A pergunta a ser feita é se é possível recuperar todas as informações no sistema primitivo a partir da forma reduzida. Em outras palavras, é preciso saber se a forma primitiva é identificável.

A menos que se coloque uma restrição no sistema primitivo, esse modelo não pode, assim, ser identificado; o número de parâmetros recuperados é menor que o número de parâmetros da forma primitiva (há mais incógnitas que equações), por isso esse sistema primitivo é sub-identificado e não há possibilidade de solução única. Se for estabelecida uma restrição na equação em um dos parâmetros do sistema primitivo (i.e. $b_{21}=0$), tem-se o número de parâmetros recuperados da forma

reduzida igual ao número de parâmetros da forma primitiva. Assim, esse modelo passa a ser exatamente identificável.

No entanto, ao restringir mais de um parâmetro da forma primitiva, tem-se o número de parâmetros recuperados maior que o número de parâmetros de forma primitiva (número de equações maior que o de incógnitas), e o sistema primitivo é sobreidentificado, entretanto, com possibilidade de solução.

A decomposição da variância do erro de previsão indica a proporção do movimento na seqüência de uma variável, devido ao seu próprio choque puro versus os choques puros de outras variáveis que compõem o modelo VAR. Se, por exemplo, os choques ε_{zt} não explicam nada de $\sigma_y(n)^2$ em todo o horizonte de previsão, pode-se dizer que a seqüência $\{Y_t\}$ é exógena.

Entretanto, se ε_{zt} pode explicar completamente $\sigma_y(n)^2$, caracteriza-se $\{Y_t\}$ como endógena. Na prática, a variância do erro de previsão de uma variável é total ou quase totalmente explicada por seus próprios choques no curto prazo.

3. RESULTADOS E DISCUSSÕES

Neste capítulo descrevemos os resultados empíricos dos modelos de previsão mensal do ISSQN de Teresina. Para sua elaboração escolhemos as abordagens VAR e Box-Jenkins descritas na revisão da literatura, por serem adequadas ao tratamento de dados em séries temporais.

A base de dados utilizada para realizar as simulações² aplica-se exclusivamente ao período de janeiro de 2002 a dezembro de 2006, num total de 60 observações. Dispõe de valores quantitativos e monetários. Estes, atualizados para o início das séries através do IPCA_E divulgado mensalmente pelo IBGE.

Todas as variáveis foram transformadas, tornando-se o seu logaritmo. Quando a denominação de uma variável aparece precedida pela letra “D” indica a primeira diferença da variável. Quando a denominação de uma variável aparece precedida pela letra “L” indica que ela está expressa em logaritmo. A razão para se trabalhar em logaritmos é tornar as séries temporais econômicas mais homogêneas.

A diferenciação logarítmica é aplicada às séries de tempo com o propósito de estabilizar a tendência crescente da variância das séries originais.

Fez-se uma combinação das transformações em primeira diferença com as transformações logarítmicas para considerar taxa de crescimento da série original.

Sendo assim, as variáveis receberam a denominação a seguir:

DLARRECISSR: diferença do logaritmo do valor monetário da arrecadação mensal do ISSQN

DLTRANSPASS: diferença do logaritmo da quantidade mensal de passageiros de transportes coletivos urbano

DLCONSUENER: diferença do logaritmo da quantidade mensal de Megawatts de energia consumida

DLFISTRIBUT: diferença do logaritmo da quantidade mensal de fiscalizações efetuadas.

2 Utilização do software Eviews, versão 5

3.1 Análise do modelo VAR

Preliminarmente, submeteu-se as variáveis DLTRANSPASS (vide tabela 2 – em anexo)³ e DLCONSUEENER (vide tabela 3 em anexo) ao teste de raiz unitária para verificar sua estacionariedade ou não, através da estatística ADF realizada em nível, com intercepto e tendência.

No teste a hipótese nula é a de que existe uma raiz unitária. Verificou-se na DLTRANSPASS valor -5.385360 à esquerda de -3.487845 ao nível de significância 5%. E, na DLCONSUEENER valor de -6.038744, também à esquerda de -3.498692, para o mesmo nível de significância.

Portanto, deduz-se que estas variáveis são estacionárias. Para as variáveis DLARRECISSR (vide tabela 4 anexa) e DLFISTRIBUT (vide tabela 5 anexa) adotou-se o teste ERS devido a existência de quebra estrutural a partir de fevereiro de 2004. Nele, especificou-se uma constante e uma tendência como regressores. Além de usar o método MQO para estimar o espectro residual numa frequência zero.

Na estatística teste a hipótese nula é a de que existe um ponto ótimo viável de nulidade. Observou-se na DLARRECISSR valor 39.40781 à direita de 5.704000 ao nível de significância de 5%. E, na DLFISTRIBUT valor 3.235884, entretanto à esquerda de 5.705600, para o mesmo nível de significância. Pelos resultados encontrados pode-se afirmar que a DLARRECISSR é não estacionária, porém a DLFISTRIBUT é estacionária.

O passo seguinte foi determinar até que ponto o passado dessas variáveis é importante para explicar o presente através da análise do critério de seleção de *lags* de Schwarz, conforme Tabela 6 (vide anexo).

Por este critério, a quantidade ótima de defasagem será a menor, no caso, uma defasagem. Dessa forma tem-se o modelo VAR corretamente identificado e estimado na forma da equação a seguir.

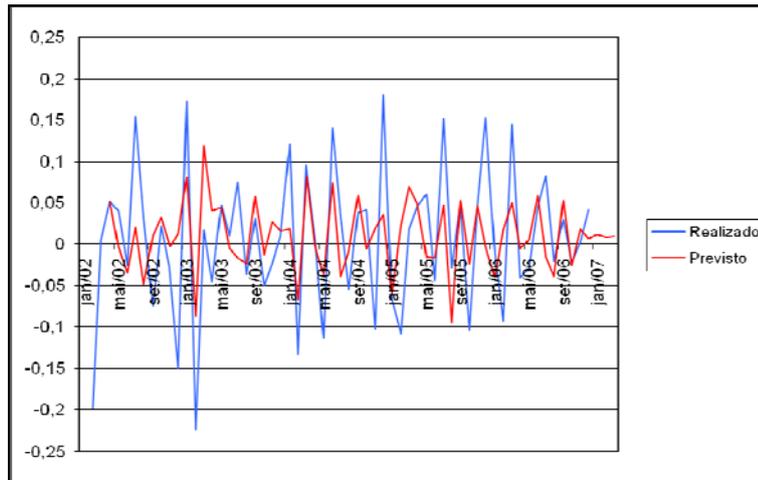
$$\text{DLARRECISSR} = -0.4353605103 \cdot \text{DLARRECISSR}(-1) - 0.1428753309 \cdot \text{DLCONSUEENER}(-1) - 0.03459616964 \cdot \text{DLFISTRIBUT}(-1) + 0.1919547627 \cdot \text{DLTRANSPASS}(-1) + 0.01520462744$$

³ Para efeito de visualização todas as tabelas estarão dispostas no anexo do trabalho.

Através da análise da estatística t verificou-se que os coeficientes das equações são estatisticamente diferentes de zero, ou seja, todos são significantes ao nível de 5%.

O gráfico seguinte mostra quão bem ajustado ficaram os valores estimados à série utilizada para previsão do modelo.

Gráfico 5: Valores previstos x realizados - Modelo VAR em Diferença



Fonte: Elaboração do autor

O modelo VAR gerou uma estimativa confiável, com base nos mínimos quadrados recursivos e calculado, para cada t , o erro de previsão a h passos para ser utilizado nas medidas de ajuste do erro quadrático médio (EQM). Quando erros elevados são inaceitáveis, o método sugerido é o erro quadrático médio, o qual penaliza os erros grandes, elevando-os ao quadrado. Esse método é representado por

$$EQM = \frac{\sum (x_t - \hat{x})^2}{n}$$

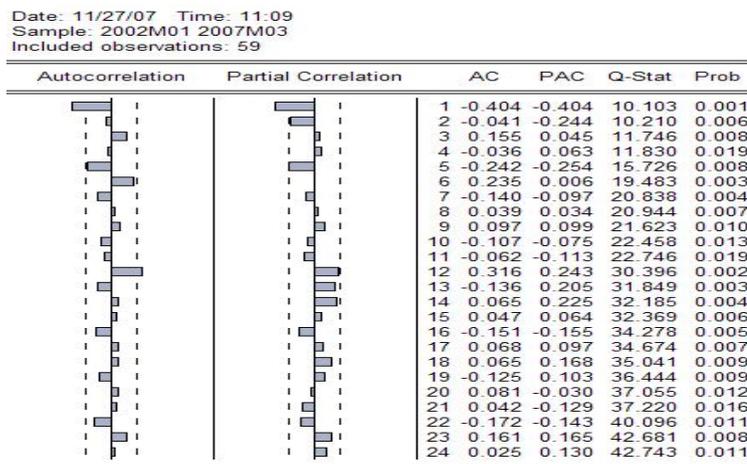
O valor do EQM de 7% encontrado para o modelo VAR, valor considerável quando comparado a outros estudos já realizados. A partir dos dados estudados gerou-se a previsão *ex-post*, de julho a outubro de 2006. Na seção 3.3 por meio da tabela comparativa apresentamos os valores previstos por esse modelo.

3.2. Análise do Modelo Box-Jenkins

A modelagem ARMA(p,q) objetiva construir um modelo autoregressivo de média móvel ajustado ao conjunto de dados e que descreva o processo estocástico gerador da série temporal.

Através da verificação da FAC e FACP do correlograma dos resíduos de estimação (Gráfico 6) observou-se que a série era não estacionária, portanto, inadequada para fazer-se uma previsão com esse tipo de abordagem. Sendo mais apropriada ao modelo ARIMA(p,d,q).

Gráfico 6: Correlograma dos resíduos de estimação



Fonte: Elaboração do autor

Para identificar o processo ARIMA(p,d,q) é necessário determinar as ordens p,d e q, que fornecessem o melhor ajuste possível do modelo.

Pela análise do correlograma dos resíduos há indícios de que deve-se atribuir, inicialmente, uma ordem tipo ARIMA(3,1,3) ao modelo. Nesta ordem, as variáveis estudadas apresentaram coeficientes não significantes. Motivo suficiente para sua exclusão do processo.

Também, percebeu-se haver indícios de sazonalidade anual no décimo segundo período do correlograma. Este fato justifica a inclusão de termos sazonais do AR e do MA. Logo, houve uma transformação para um SARIMA (3,1,3)(12,0,12) (vide tabela 10 - anexo). Onde, o termo(3,1,3) significa que AR e MA assumiram o valor três, cada.

Como a variável dependente DLARRCESSIR está com uma defasagem recebeu o valor um. Outro termo (12,0,12) indicou o período da sazonalidade. Sendo, o primeiro 12 para o AR e o último para o MA. O zero representou a defasagem.

Para calcular o modelo SARIMA(3,1,3)(12,0,12) incluiu-se a variável dummy em função da existência de quebra estrutural na variável dependente. Essa variável apresentou um coeficiente de 0.10356, considerado não significativo.

Com isso, retirou-se a dummy (vide tabela 11 em anexo). Os valores dos coeficientes de AR(1), AR(3) e MA(2) resultaram em -0.263648, 0.042096 e 0.497949, respectivamente. Portanto, excluídos por serem insignificantes.

Conforme exposto na Tabela 12 (anexo), quando o modelo assumiu a configuração SARIMA (2,1,3)(12,0,12), observou-se valores -0.177097 para AR(2) e 0.121109 para MA(3), considerados insignificantes, o que sugeriu calcular a forma SARIMA(0,1,1)(12,0,12).

Por cautela, preferiu-se, antes testar com os termos SARIMA (2,1,2)(12,0,12). Neste, os valores de AR(1) e AR(2) resultaram insignificantes. De outro modo, ao tentar na forma SARIMA (1,1,1)(12,0,12) (vide Tabela 13 - anexo), o AR(1) assumiu valor insignificante e os demais termos significantes.

Daí, iniciou-se a análise do modelo SARIMA (0,1,1)(12,0,12) que, devido à inexistência de termo AR, o SAR(12) passou a ser AR(12).

Então, chegou-se ao modelo SARIMA (12,1,1)(0,0,12), onde todos os coeficientes estimados são significantes, respeitando as condições de invertibilidade e estacionaridade da série (vide Tabela 14 - anexo).

Finalmente, pelos resultados apresentados acima, deduz-se que os modelos especificados por SARIMA (12,1,1)(0,0,12) SARIMA(1,1,1)(12,0,12) são os mais bem ajustados para realizar a previsão. Porém, pela análise do critério de informação de Schwarz (vide tabela 15 - anexo), o modelo SARIMA (12,1,1)(0,0,12) obteve o valor -3004254, portanto, inferior ao SARIMA(1,1,1)(12,0,12), fato este, que demonstra sua melhor especificação.

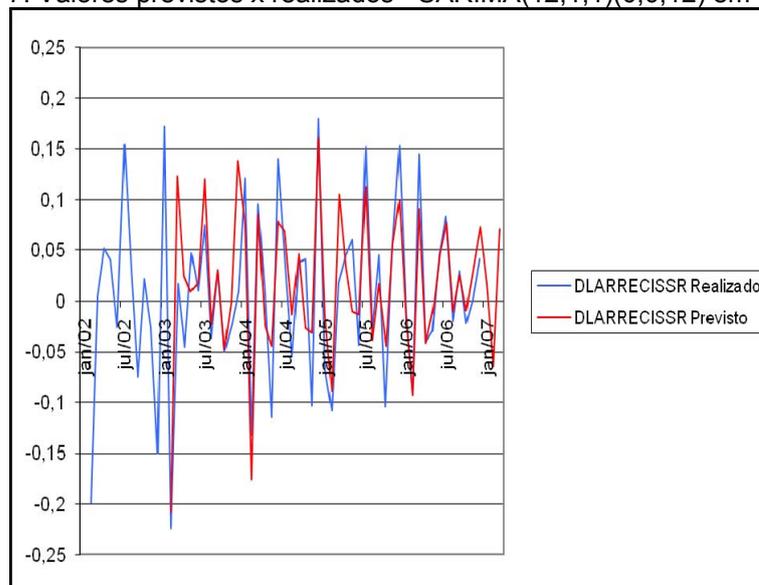
Dessa forma, o modelo melhor estimado pode ser representado pela equação abaixo:

$$\text{SARIMA}(12,1,1)(0,0,12)=0,0288222 + 0,795183\text{Larrecissr}_{t-12} - 0,544873\varepsilon_{t-1} - 0,9244889\varepsilon_{t-12} + \varepsilon_t$$

Através da análise dos valores da estatística Q (anexo gráfico 9) fez-se o diagnóstico dos resíduos desse modelo. Considerando utilizada apenas uma defasagem, a estatística Q resultou em valor suficiente para rejeição da hipótese nula de que os resíduos dessa especificação sejam autocorrelacionados ao nível de significância de 5% (p valor (1)=0,3405). Portanto, o diagnóstico indica que os resíduos do modelo apresentam as propriedades de ruído branco.

No Gráfico 7 pode-se observar o grau de ajustamento da estimativa do modelo SARIMA(12,1,1)(0,0,12) aos valores realizados no período de jan/02 a dez/06.

Gráfico 7: Valores previstos x realizados - SARIMA(12,1,1)(0,0,12) em diferença



Fonte: Elaboração do autor

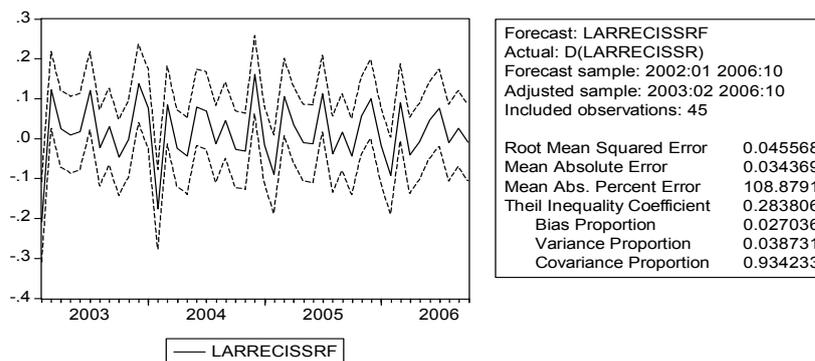
Cumpridas as etapas de identificação, estimação e do diagnóstico partiu-se para a etapa da previsão.

3.2.1 Previsão modelo SARIMA(12,1,1)(0,0,12)

As previsões dos valores de arrecadação foram realizadas em termos da diferença do logaritmo neperiano, que representa a taxa de crescimento. Por conseguinte, há necessidade de fazer uma operação inversa para apresentar os valores em termos monetários constante na Tabela 16.

Para medir a performance do modelo SARIMA(12,1,1)(0,0,12) adotou-se o método do erro quadrático médio que verifica a proximidade dos valores previstos aos valores realizados, no período em estudo. Através da análise do Gráfico 8 evidenciamos um EQM de 4,5, portanto, boa capacidade preditiva.

Gráfico 8: Previsão SARIMA(12,1,1)(0,0,12) em diferença



Fonte: Elaboração do autor

3.3 Comparação dos modelos de previsão

Os modelos VAR e SARIMA apresentaram desvios entre o realizado e projetado, sendo que o modelo VAR subestimou a receita total do ISSQN (Tabela 16 em anexo) nos meses de jul, ago e out de 2006, principalmente no primeiro mês, registrando uma variação percentual de 9,4%, equivalente a R\$ 284.315,49. De outro modo, superestimou a receita no mês de set/06, com uma variação percentual de 2,3%.

No modelo SARIMA verificou-se uma subestimação nos meses de julho e set/06, ambas em 0,7%, porém com grande aproximação. Já nos meses de agosto e

out/06, houve superestimação da receita, onde o primeiro em 1,3%, portanto superior ao segundo.

Quando comparado o índice de avaliação da previsão geral, o modelo SARIMA obteve o melhor desempenho preditivo, com um EQM de 4,5%, enquanto o valor do EQM do modelo VAR resultou em 7%, valor considerado elevado para estudo da espécie. Portanto, o SARIMA demonstrou ser o mais acurado para realizar a previsão do ISSQN de Teresina.

CONCLUSÃO

Este estudo teve como objetivo propor um modelo de previsão de arrecadação do ISSQN para a Prefeitura de Teresina, através de séries temporais, em função desse imposto ser a principal fonte de receita própria na estrutura tributária da cidade. Ele representou 58% e 38% das receitas próprias municipal, em 2002 e 2005, respectivamente, conforme Relatório de Atividades Municipais.

Resguardadas as devidas proporções o ISSQN está concentrado principalmente em setores como instituições financeiras, transporte, educação e saúde.

De acordo com Relatório de Atividades de Teresina, período 2002 a 2006, o crescimento da economia municipal é sustentada pelo setor de serviços, possuidor de um grande potencial de arrecadação do ISSQN. E diante da possibilidade de crescimento da receita municipal justifica a adoção de um instrumental técnico com reconhecido poder de previsão, como no caso dos modelos VAR e a abordagem Box-Jenkins.

Para estudar os modelos, iniciou-se um levantamento bibliográfico que servisse de base para realizar previsões *ex-post*, para o período de julho a outubro de 2006. Posteriormente, fez-se a análise dos resultados empíricos encontrados.

Para que as séries recebessem um tratamento adequado aplicou-se uma diferença de logaritmo em todas elas, assim os resultados das previsões foram expressos em termos de taxa de crescimento. Posteriormente, essa taxa foi transformada em valores monetários para tornar possível uma comparação com os valores efetivamente arrecadados pelo município.

Nessa comparação observou-se que o modelo VAR obteve resultado bastante aproximado para o mês de outubro de 2006, com uma variação de -0,4%, no entanto, para julho do mesmo ano, indicou uma variação de -9,4%, valor acima em relação outros resultados apresentados em trabalhos com séries temporais. Além disso, um EQM de 7% reduz sua capacidade preditiva.

Vale ressaltar que o modelo SARIMA(12,1,1)(0,0,12) apresentou previsões bastante aproximadas dos valores arrecadados pela Prefeitura de Teresina, sendo de -0,7% para os meses de julho e setembro de 2006, e de 1,3% para outubro do mesmo ano, bem como um EQM de 4,5%, demonstrando de seu grande poder preditivo.

Assim, pelos resultados acima descritos, o modelo SARIMA(12,1,1)(0,0,12) possui um melhor desempenho para previsão do ISSQN de Teresina, podendo ser adotado como instrumento auxiliar para contribuir para o incremento da arrecadação tributária municipal.

Contudo, acredita-se que esta dissertação oferecerá uma contribuição mais robusta, quando a Prefeitura de Teresina trabalhar com metas de arrecadação do tributo em estudo, com base em técnicas econométricas, não apenas de forma intuitiva como até o presente momento. Isso facilitará o aprofundamento das discussões aqui tratadas. O campo está aberto a outros pesquisadores que tenham interesse nesse tema.

BIBLIOGRAFIA

ABRAHAMSOHN, P. **Redação científica**. Rio de Janeiro: Guanabara, 2004.

_____. **Econometria financeira: um curso em séries temporais financeiras**. São Paulo: Associação Brasileira de Estatística, 2006.

BIDERMAN, C. **Arrecadação dos municípios da região metropolitana de São Paulo com ênfase no ISS. EAESP / FGV** (Texto para discussão). São Paulo, 2005.

BIDERMAN, C; Arvate P. (Org). **Economia do setor público no Brasil**. Rio de Janeiro: Campus, 2004.

CALDART, W. L. **Modelo de previsão de arrecadação do issqn para o município de Caxias do sul**. Caxias do Sul, 2006, n. 021, maio de 2006. Disponível em: <<http://www.ucs.br/html>>. Acesso em: 18.02.07.

CARVALHO, F. E. **Análise das receitas tributárias municipais em Sergipe, de 1984 a 2004, e alternativas de incremento**. Brasília, 2006 (XI Prêmio Tesouro Nacional /ESAF)

CASTELAR, Ivan; ARRAES, Ronaldo A. **Modelos de previsão das finanças públicas do estado do Ceará: receitas**. Vol. 1. Fortaleza: UFC / CAEN, 2003.

ENDERS, Walter. **Applied econometric time series**. 2. ed. River Street: John Wiley & Sons, inc., 2004.

FERREIRA, R. T. **Modelos de análise de séries temporais para previsão do icms mensal do estado do Ceará**. Fortaleza, 1996. Dissertação (Mestrado) – Universidade Federal do Ceará.

GIAMBIAGI Fábio; Além, C. A. **Finanças públicas: teoria e prática no Brasil**. 2. Ed. Rio de Janeiro: Campus, 2000.

GUJARATI, Damodar. **Econometria básica**. Tradução de Maria J. C. Monteiro. 4. ed. Rio de Janeiro: Campus, 2006.

IPEA (Coord.). **O comportamento recente das receitas públicas no Brasil**. Boletim de Desenvolvimento Fiscal. Brasília, 2006, n.02, setembro 2006, Disponível em: <<http://www.ipea.gov.br/html>>. Acesso em: 18.02.07.

KHAIR, A. A; VIGNOLI F. H. (Coord). **Manual de orientação para crescimento da receita própria municipal**. 2. Ed. São Paulo: EAESP/FGV, 2001.

KON, A. **Economia de serviços: teoria e evolução no Brasil**. Rio de Janeiro: Campus, 2004.

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

MANGIERI, F. R. **Iss: teoria, prática, questões polêmicas**. 3. Ed. São Paulo: Edipro, 2003.

MARTINS, S. P. **Manual do imposto sobre serviços**. 7. Ed. São Paulo: Atlas, 2006.

MELO, Bruno Stephan Veras de. **Modelo de previsão para arrecadação tributária**. Brasília, 2001.(VI Prêmio Tesouro Nacional/ESAF)

MORETTIN, Pedro A; TOLOI, Clélia M. C. **Análises de séries temporais**. São Paulo: Edgard Blücher, 2004.

PARKER, G; RILEY J. **Previsão de impostos realizada pelo governo do reino unido**. **Boletim de Desenvolvimento Fiscal**. Brasília, 2006, n.02, setembro 2006, Disponível em: <<http://www.ipea.gov.br/html>>. Acesso em: 18.02.07.

ROCHA, F. G. **Contribuição de modelos de séries temporais para a previsão da arrecadação do ISS**. Campinas, 2003. Dissertação (Mestrado) – Unicamp / Instituto de Economia.

SANTOS, C. H; RIBEIRO, M. B. **Como prever ou explicar o comportamento das receitas públicas no Brasil?: antigas e novas alternativas**. Boletim de Desenvolvimento Fiscal. Brasília, 2006, n.02, setembro 2006. Disponível em: <<http://www.ipea.gov.br/html>>. Acesso em: 18.02.07.

SIQUEIRA, M. L. **Melhorando a previsão da arrecadação tributária federal através da utilização de modelos de séries temporais**. Brasília, 2002 (VII Prêmio Tesouro Nacional/ESAF.)

WOOLDRIDGE, Jeffrey M. **Introdução à econometria: uma abordagem moderna**. Tradução de Rogério C. de Sousa; José A. Ferreira. São Paulo: Thomson Learning, 2006.

ANEXOS

Tabela 1: Propriedades da FAC e FACP

PROCESSO	FAC	FACP
Ruído branco	Todo $\rho_s = 0$	Todo $\phi_s = 0$
AR (1): $\phi_1 > 0$	Decaimento exponencial direto: $\rho_s = \rho_1^s$	$\phi_{2s} = \rho_1^s$; $\phi_{2s+1} = 0$ para $s(< \text{ou} =)$ a 2
AR (1): $\phi_1 < 0$	Decaimento oscilatório: $\rho_s = \rho_1^s$	$\phi_{2s} = \rho_1^s$; $\phi_{2s+1} = 0$ para $s(< \text{ou} =)$ a 2
AR (p)	Decaimento em direção a zero. Coeficientes podem isolar	Picos até o lag p. todos $\phi_s = 0$ para $s > p$
MA (1): $\theta > 0$	"Pico" positivo na lag 1. $=0$ para $s(> \text{ou} =)$ a 2	Decaimento oscilatório: >0
MA (1): $\theta < 0$	"Pico" negativo na lag 1. $=0$ para $s(> \text{ou} =)$ a 2	Decaimento: <0
ARMA (1,1):	Decaimento exponencial a partir do lag 1.	Decaimento oscilatório a partir do lag 1.
ARMA (1,1):	Decaimento oscilatório a partir do lag 1.	Decaimento exponencial a partir do lag 1.
ARMA (p,q)	Decaimento (direto ou oscilatório) a partir do lag q	Decaimento (direto ou oscilatório) a partir do lag p.

Fonte: Enders - 1995

Tabela 2: Teste ADF para ltranspass

Null Hypothesis: LTRANSPASS has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.385360	0.0002
Test critical values: 1% level	-4.121303	
5% level	-3.487845	
10% level	-3.172314	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(LTRANSPASS)

Method: Least Squares

Date: 11/18/07 Time: 15:46

Sample(adjusted): 2002:02 2006:12

Included observations: 59 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LTRANSPASS(-1)	-0.681088	0.126470	-5.385360	0.0000
C	10.74678	1.995295	5.386059	0.0000
@TREND(2002:01)	-0.000103	0.000603	-0.171243	0.8646
R-squared	0.341201	Mean dependent var		0.001405
Adjusted R-squared	0.317672	S.D. dependent var		0.095519
S.E. of regression	0.078902	Akaike info criterion		-2.191717
Sum squared resid	0.348627	Schwarz criterion		-2.086079
Log likelihood	67.65565	F-statistic		14.50155
Durbin-Watson stat	1.900127	Prob(F-statistic)		0.000008

Fonte: Elaboração do autor

Tabela 3: Teste ADF para lconsuener

Null Hypothesis: LCONSUENER has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 7 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.038744	0.0000
Test critical values: 1% level	-4.144584	
5% level	-3.498692	
10% level	-3.178578	

*MacKinnon (1996) one-sided p-values.
 Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(LCONSUENER)
 Method: Least Squares
 Date: 11/18/07 Time: 15:43
 Sample(adjusted): 2002:09 2006:12
 Included observations: 52 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LCONSUENER(-1)	-1.602657	0.265396	-6.038744	0.0000
D(LCONSUENER(-1))	0.920967	0.197504	4.663023	0.0000
D(LCONSUENER(-2))	0.898400	0.187626	4.788251	0.0000
D(LCONSUENER(-3))	0.838505	0.187155	4.480283	0.0001
D(LCONSUENER(-4))	0.451407	0.156695	2.880798	0.0062
D(LCONSUENER(-5))	0.482953	0.133422	3.619731	0.0008
D(LCONSUENER(-6))	0.316311	0.131256	2.409880	0.0204
D(LCONSUENER(-7))	0.226711	0.121645	1.863705	0.0694
C	17.47621	2.891978	6.042995	0.0000
@TREND(2002:01)	0.005904	0.001093	5.401687	0.0000
R-squared	0.529156	Mean dependent var		0.004764
Adjusted R-squared	0.428261	S.D. dependent var		0.062608
S.E. of regression	0.047340	Akaike info criterion		-3.091891
Sum squared resid	0.094124	Schwarz criterion		-2.716652
Log likelihood	90.38918	F-statistic		5.244611
Durbin-Watson stat	2.069821	Prob(F-statistic)		0.000087

Fonte: Elaboração do autor

Tabela 4: Teste ERS para larrecissr

Null Hypothesis: LARRECISSR has a unit root
 Exogenous: Constant, Linear Trend
 Lag length: 2 (Spectral OLS AR based on SIC, MAXLAG=10)
 Sample: 2002:01 2006:12
 Included observations: 60

	P-Statistic
Elliott-Rothenberg-Stock test statistic	39.40781
Test critical 1% level	4.228000
values:	
5% level	5.704000
10% level	6.774000
*Elliott-Rothenberg-Stock (1996, Table 1)	
HAC corrected variance (Spectral OLS autoregression)	0.001595

Fonte: Elaboração do autor

Tabela 5: Teste ERS para lfistribut

Null Hypothesis: LFISTRIBUT has a unit root
 Exogenous: Constant, Linear Trend
 Lag length: 3 (Spectral OLS AR based on SIC, MAXLAG=10)
 Sample(adjusted): 2002:02 2006:12
 Included observations: 59 after adjusting endpoints

	P-Statistic
Elliott-Rothenberg-Stock test statistic	3.235884
Test critical 1% level	4.227200
values:	
5% level	5.705600
10% level	6.773600
*Elliott-Rothenberg-Stock (1996, Table 1)	
HAC corrected variance (Spectral OLS autoregression)	0.090997

Fonte: Elaboração do autor

Tabela 6: Critério de seleção de lags de Schwarz

VAR Lag Order Selection Criteria
 Endogenous variables: LARRECISSR LCONSUENER LFISTRIBUT LTRANSPASS
 Exogenous variables: C DUMMY SDUMMY
 Date: 11/22/07 Time: 19:22
 Sample: 2002:01 2006:12
 Included observations: 52

Lag	LogL	LR	FPE	AIC	SC	HQ
0	165.4118	NA	3.22E-08	-5.900452	-5.450165	-5.727823
1	238.8468	127.0992	3.56E-09	-8.109494	-7.058824*	-7.706692
2	265.4456	41.94413	2.41E-09	-8.517137	-6.866085	-7.884163*
3	279.0174	19.31381	2.76E-09	-8.423747	-6.172312	-7.560600
4	299.0377	25.41028	2.55E-09	-8.578371	-5.726554	-7.485052
5	325.3893	29.39222*	1.93E-09*	-8.976512	-5.524311	-7.653019
6	336.3555	10.54439	2.82E-09	-8.782902	-4.730319	-7.229238
7	359.0037	18.29281	2.89E-09	-9.038604*	-4.385638	-7.254767

* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

Fonte: Elaboração do autor

Tabela 7: Estimação modelo VAR em diferença

Vector Autoregression Estimates
Date: 11/13/07 Time: 00:44
Sample(adjusted): 2002:04 2006:12
Included observations: 57 after adjusting endpoints
Standard errors in () & t-statistics in []

	DLARRECIS SR	DLCONSUE NER	DLFISTRIBU T	DLTRANSPA SS
DLARRECISSR(-1)	-0.435361 (0.12299) [-3.53971]	0.010883 (0.08360) [0.13018]	-0.209836 (0.29447) [-0.71259]	-0.165893 (0.13970) [-1.18751]
DLCONSUENER(-1)	-0.142875 (0.15619) [-0.91473]	-0.111936 (0.10617) [-1.05436]	-0.463053 (0.37396) [-1.23825]	-0.429272 (0.17741) [-2.41969]
DLFISTRIBUT(-1)	-0.034596 (0.05522) [-0.62654]	0.030508 (0.03753) [0.81287]	0.315606 (0.13220) [2.38731]	0.046652 (0.06272) [0.74386]
DLTRANSPASS(-1)	0.191955 (0.10856) [1.76820]	0.436299 (0.07379) [5.91289]	0.304330 (0.25991) [1.17090]	-0.235096 (0.12330) [-1.90665]
C	0.015205 (0.01021) [1.48849]	0.007357 (0.00694) [1.05961]	0.020572 (0.02446) [0.84117]	0.004897 (0.01160) [0.42206]
R-squared	0.260512	0.437825	0.157172	0.193380
Adj. R-squared	0.203629	0.394581	0.092340	0.131332
Sum sq. resids	0.298449	0.137882	1.710754	0.385025
S.E. equation	0.075759	0.051493	0.181381	0.086048
F-statistic	4.579741	10.12448	2.424270	3.116633
Log likelihood	68.80838	90.81623	19.04483	61.54922
Akaike AIC	-2.238890	-3.011096	-0.492801	-1.984183
Schwarz SC	-2.059675	-2.831881	-0.313586	-1.804968
Mean dependent	0.009869	0.009131	0.024236	-5.51E-05
S.D. dependent	0.084894	0.066179	0.190384	0.092324
Determinant Residual		3.12E-09		
Covariance				
Log Likelihood (d.f. adjusted)		234.6962		
Akaike Information Criteria		-7.533200		
Schwarz Criteria		-6.816340		

Fonte: Elaboração do autor

Tabela 8: Resultados da estimação modelo VAR

Estimation Proc:

=====

LS 1 1 DLARRECISSR DLCONSUENER DLFISTRIBUT DLTRANSPASS @ C

VAR Model:

=====

DLARRECISSR = C(1,1)*DLARRECISSR(-1) + C(1,2)*DLCONSUENER(-1) + C(1,3)*DLFISTRIBUT(-1) + C(1,4)*DLTRANSPASS(-1) + C(1,5)

DLCONSUENER = C(2,1)*DLARRECISSR(-1) + C(2,2)*DLCONSUENER(-1) + C(2,3)*DLFISTRIBUT(-1) + C(2,4)*DLTRANSPASS(-1) + C(2,5)

DLFISTRIBUT = C(3,1)*DLARRECISSR(-1) + C(3,2)*DLCONSUENER(-1) + C(3,3)*DLFISTRIBUT(-1) + C(3,4)*DLTRANSPASS(-1) + C(3,5)

DLTRANSPASS = C(4,1)*DLARRECISSR(-1) + C(4,2)*DLCONSUENER(-1) + C(4,3)*DLFISTRIBUT(-1) + C(4,4)*DLTRANSPASS(-1) + C(4,5)

VAR Model - Substituted Coefficients:

=====

DLARRECISSR = - 0.4353605103*DLARRECISSR(-1) - 0.1428753309*DLCONSUENER(-1) - 0.03459616964*DLFISTRIBUT(-1) + 0.1919547627*DLTRANSPASS(-1) + 0.01520462744

DLCONSUENER = 0.01088313652*DLARRECISSR(-1) - 0.1119364273*DLCONSUENER(-1) + 0.03050818052*DLFISTRIBUT(-1) + 0.4362994246*DLTRANSPASS(-1) + 0.007356872618

DLFISTRIBUT = - 0.2098359655*DLARRECISSR(-1) - 0.4630528859*DLCONSUENER(-1) + 0.3156059235*DLFISTRIBUT(-1) + 0.3043295965*DLTRANSPASS(-1) + 0.0205719028

DLTRANSPASS = - 0.1658931268*DLARRECISSR(-1) - 0.4292715091*DLCONSUENER(-1) + 0.04665247982*DLFISTRIBUT(-1) - 0.2350963468*DLTRANSPASS(-1) + 0.004896835938

Fonte: Elaboração do autor

Tabela 9: Estimação modelo SARIMA(3,1,3)(12,0,12) com *dummy*

Dependent Variable: D(LARRECISSR)
Method: Least Squares
Date: 11/18/07 Time: 23:58
Sample(adjusted): 2003:05 2006:12
Included observations: 44 after adjusting endpoints
Convergence achieved after 59 iterations
Backcast: 2002:02 2003:04

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.011315	0.009339	1.211605	0.2340
DUMMY	0.010356	0.007270	1.424569	0.1634
AR(1)	-0.358848	0.335154	-1.070694	0.2918
AR(2)	-0.794513	0.166389	-4.775017	0.0000
AR(3)	-0.022323	0.166151	-0.134355	0.8939
SAR(12)	0.659685	0.105832	6.233332	0.0000
MA(1)	-0.687315	0.295054	-2.329455	0.0259
MA(2)	0.436529	0.378611	1.152974	0.2570
MA(3)	-0.743777	0.231562	-3.212001	0.0029
SMA(12)	-0.962205	0.038254	-25.15300	0.0000
R-squared	0.764282	Mean dependent var		0.014037
Adjusted R-squared	0.701886	S.D. dependent var		0.077749
S.E. of regression	0.042451	Akaike info criterion		-3.284231
Sum squared resid	0.061270	Schwarz criterion		-2.878733
Log likelihood	82.25308	F-statistic		12.24888
Durbin-Watson stat	1.719815	Prob(F-statistic)		0.000000
Inverted AR Roots	.97	.84+.48i	.84 -.48i	.48+.84i
	.48 -.84i	.00+.97i	-.00 -.97i	-.03
	-.17 -.87i	-.17+.87i	-.48+.84i	-.48 -.84i
	-.84 -.48i	-.84+.48i		-.97
Inverted MA Roots	1.00	1.00	.86 -.50i	.86+.50i
	.50+.86i	.50 -.86i	.00+1.00i	-.00 -
				1.00i
	-.16 -.85i	-.16+.85i	-.50+.86i	-.50 -.86i
	-.86+.50i	-.86 -.50i	-1.00	

Fonte: Elaboração do autor

Tabela 10: Estimação modelo SARIMA(3,1,3)(12,0,12) sem *dummy*

Dependent Variable: D(LARRECISSR)
Method: Least Squares
Date: 11/18/07 Time: 23:59
Sample(adjusted): 2003:05 2006:12
Included observations: 44 after adjusting endpoints
Convergence achieved after 29 iterations
Backcast: 2002:02 2003:04

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.022540	0.002571	8.768223	0.0000
AR(1)	-0.263648	0.354674	-0.743354	0.4622
AR(2)	-0.802738	0.143983	-5.575237	0.0000
AR(3)	0.042096	0.181363	0.232112	0.8178
SAR(12)	0.557772	0.088425	6.307869	0.0000
MA(1)	-0.656310	0.322319	-2.036216	0.0494
MA(2)	0.497949	0.366307	1.359379	0.1827
MA(3)	-0.737010	0.196894	-3.743177	0.0007
SMA(12)	-0.937616	0.034239	-27.38439	0.0000
R-squared	0.754588	Mean dependent var		0.014037
Adjusted R-squared	0.698493	S.D. dependent var		0.077749
S.E. of regression	0.042692	Akaike info criterion		-3.289383
Sum squared resid	0.063790	Schwarz criterion		-2.924435
Log likelihood	81.36643	F-statistic		13.45214
Durbin-Watson stat	1.983673	Prob(F-statistic)		0.000000
Inverted AR Roots	.95	.82 -.48i	.82+.48i	.48+.82i
	.48 -.82i	.05	.00+.95i	-.00 -.95i
	-.16+.89i	-.16 -.89i	-.48+.82i	-.48 -.82i
	-.82+.48i	-.82 -.48i	-.95	
Inverted MA Roots	.99	.95	.86+.50i	.86 -.50i
	.50+.86i	.50 -.86i	.00+.99i	-.00 -.99i
	-.15 -.87i	-.15+.87i	-.50+.86i	-.50 -.86i
	-.86+.50i	-.86 -.50i	-.99	

Fonte: Elaboração do autor

Tabela 11: Estimação modelo SARIMA(2,1,3)(12,0,12)

Dependent Variable: D(LARRECISSR)
Method: Least Squares
Date: 11/19/07 Time: 00:01
Sample(adjusted): 2003:04 2006:12
Included observations: 45 after adjusting endpoints
Convergence achieved after 33 iterations
Backcast: 2002:01 2003:03

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.023175	0.003501	6.618639	0.0000
AR(2)	-0.177097	0.192222	-0.921317	0.3625
SAR(12)	0.547879	0.081946	6.685821	0.0000
MA(1)	-0.847324	0.143177	-5.918024	0.0000
MA(3)	0.121109	0.107070	1.131113	0.2649
SMA(12)	-0.930804	0.030535	-30.48335	0.0000
R-squared	0.732284	Mean dependent		0.012718
		var		
Adjusted R-squared	0.697962	S.D. dependent var		0.077368
S.E. of regression	0.042520	Akaike info criterion		-3.354129
Sum squared resid	0.070509	Schwarz criterion		-3.113241
Log likelihood	81.46790	F-statistic		21.33538
Durbin-Watson stat	2.035562	Prob(F-statistic)		0.000000
Inverted AR Roots	.95	.82+.48i	.82 -.48i	.48 -.82i
Inverted MA Roots	.48+.82i	.00+.95i		
	.99	.86 -.50i	.86+.50i	.58 -.19i
	.58+.19i	.50 -.86i	.50+.86i	.00+.99i
	-.00 -.99i	-.32	-.50+.86i	-.50 -.86i
	-.86+.50i	-.86 -.50i	-.99	

Fonte: Elaboração do autor

Tabela 12: Estimaco modelo SARIMA(1,1,1)(12,0,12)

Dependent Variable: D(LARRECISSR)
Method: Least Squares
Date: 11/19/07 Time: 00:03
Sample(adjusted): 2003:03 2006:12
Included observations: 46 after adjusting endpoints
Convergence achieved after 19 iterations
Backcast: 2002:02 2003:02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.020495	0.001758	11.65823	0.0000
AR(1)	0.031917	0.169885	0.187871	0.8519
SAR(12)	0.471906	0.076724	6.150674	0.0000
MA(1)	-0.906000	0.093165	-9.724691	0.0000
SMA(12)	-0.904786	0.027911	-32.41720	0.0000
R-squared	0.723096	Mean dependent		0.012812
		var		
Adjusted R-squared	0.696081	S.D. dependent var		0.076506
S.E. of regression	0.042177	Akaike info criterion		-3.391567
Sum squared resid	0.072934	Schwarz criterion		-3.192802
Log likelihood	83.00605	F-statistic		26.76640
Durbin-Watson stat	2.041608	Prob(F-statistic)		0.000000
Inverted AR Roots	.94	.81+.47i	.81 -.47i	.47+.81i
	.47 -.81i	.03	.00 -.94i	-.00+.94i
	-.47 -.81i	-.47+.81i	-.81+.47i	-.81 -.47i
	-.94			
Inverted MA Roots	.99	.91	.86 -.50i	.86+.50i
	.50 -.86i	.50+.86i	.00+.99i	-.00 -.99i
	-.50+.86i	-.50 -.86i	-.86+.50i	-.86 -.50i
	-.99			

Fonte: Elaboraco do autor

Tabela 13: Estimação modelo SARIMA(12,1,1)(0,0,12)

Dependent Variable: D(LARRECISSR)
Method: Least Squares
Date: 11/19/07 Time: 00:03
Sample(adjusted): 2003:02 2006:12
Included observations: 47 after adjusting endpoints
Convergence achieved after 15 iterations
Backcast: 2002:01 2003:01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.028222	0.016300	1.731485	0.0905
AR(12)	0.795183	0.072296	10.99898	0.0000
MA(1)	-0.544873	0.127709	-4.266508	0.0001
SMA(12)	-0.924889	0.038827	-23.82058	0.0000
R-squared	0.690814	Mean dependent var		0.007788
Adjusted R-squared	0.669243	S.D. dependent var		0.083139
S.E. of regression	0.047814	Akaike info criterion		-3.161713
Sum squared resid	0.098307	Schwarz criterion		-3.004254
Log likelihood	78.30025	F-statistic		32.02502
Durbin-Watson stat	2.136038	Prob(F-statistic)		0.000000
Inverted AR Roots	.98	.85+.49i	.85 -.49i	.49 -.85i
	.49+.85i	.00+.98i	-.00 -.98i	-.49 -.85i
	-.49+.85i	-.85+.49i	-.85 -.49i	-.98
Inverted MA Roots	.99	.86 -.50i	.86+.50i	.54
	.50 -.86i	.50+.86i	.00+.99i	-.00 -.99i
	-.50+.86i	-.50 -.86i	-.86+.50i	-.86 -.50i
	-99			

Fonte: Elaboração do autor

Tabela 14: Critério de informação de Schwarz

Modelo	Valor
SARIMA(3,1,3)(12,0,12) C/ DUMMY	-2.878733
SARIMA(3,1,3)(12,0,12) S/ DUMMY	-2.924435
SARIMA(2,1,3)(12,0,12)	-3.113241
SARIMA(2,1,2)(12,0,12)	-3.074437
SARIMA(1,1,1)(12,0,12)	-3.192802
SARIMA(12,1,1)(0,0,12)	-3.004254

Fonte: Elaboração do autor

Tabela 15: Avaliação da capacidade preditiva dos modelos

	VAR	SARIMA
Erro Médio Absoluto	0,056404	0,034166
Erro Quadrático Médio	0,072386	0,045008

Fonte: Elaboração do autor

Tabela 16: Comparativo realizado x previsto ISSQN (Período jul-out./2006)

Período	VAR			SARIMA	
	Realizado	Previsto	%	Previsto	%
Jul-06	3.018.058,78	2.733.741,29	-9,4	2.997.645,24	-0,7
Ago-06	2.958.743,94	2.904.816,73	-1,8	2.986.878,44	0,9
Set-06	3.046.991,29	3.119.453,41	2,3	3.035.723,59	-0,7
Out-06	2.980.,216,43	2.968.649,87	- 0,4	3.019.176,27	1,3

Fonte: Elaboração do autor

Gráfico 9: Correlograma de resíduos SARIMA (12,1,1) (0,0,12)

Date: 02/11/08 Time: 12:27

Sample: 2003M02 2006M12

Included observations: 47

Q-statistic probabilities adjusted for 3 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.082	-0.082	0.3405	
		2 -0.050	-0.058	0.4704	
		3 0.014	0.005	0.4813	
		4 0.085	0.085	0.8710	0.351
		5 -0.094	-0.079	1.3533	0.508
		6 -0.117	-0.126	2.1188	0.548
		7 0.119	0.091	2.9298	0.570
		8 0.165	0.176	4.5373	0.475
		9 -0.067	-0.015	4.8110	0.568
		10 -0.145	-0.148	6.1172	0.526
		11 0.051	-0.021	6.2815	0.616
		12 -0.231	-0.269	9.7895	0.368
		13 0.069	0.108	10.116	0.430
		14 0.007	0.065	10.119	0.520
		15 0.054	0.000	10.330	0.587
		16 0.052	0.042	10.527	0.650
		17 0.062	0.071	10.827	0.700
		18 0.010	0.020	10.834	0.764
		19 -0.002	0.069	10.834	0.820
		20 0.028	0.095	10.900	0.862

Fonte: Elaboração do autor