

UM MODELO ECONOMÉTRICO PARA PREVISÃO DE IMPOSTOS NO BRASIL

MÁRIO JORGE CARDOSO DE MENDONÇA*
ADOLFO SACHSIDA†
LUIS ALBERTO TOSCANO MEDRANO‡

Resumo

O objetivo deste estudo é modelar as séries individuais para uma amostra de tributos que corresponde por cerca de 80% da carga tributária bruta brasileira. Para isso, usou-se um modelo linear dinâmico bayesiano com parâmetros variáveis. A aplicação deste modelo tem como justificativa as alterações sucessivas ocorridas no sistema tributário nacional que podem implicarem mudanças nas elasticidades relevantes. Os resultados obtidos corroboraram a expectativa quanto à adequação desta metodologia. De um modo geral, temos que os valores observados para a previsão condicional fora da amostra ficaram dentro do intervalo de confiança, sendo que o erro de previsão não se situou acima de 10% nos seis primeiros meses. Os valores das elasticidades na maioria dos casos ficou abaixo da unidade.

Palavras-chave: Carga tributária brasileira; Modelo linear dinâmico com coeficientes variáveis; Métodos bayesianos; Previsão.

Abstract

The goal of this article is to model the desagregated series of taxes in Brazil. We use monthly data of a sample of taxes in charge for 80% of the Brazilian gross tax burden in the 1995-2010 years. To estimate the model we employ a Dynamic Linear Model (DLM) with variable parameter (West & Harrison 1997). The choice of this particular model was motivated by the constant changes made in the Brazilian tax system during these years. The conditional forecast is performed a year ahead out of the sample. The main conclusions of the paper are the following. In general the results seem strongly satisfactory. The forecasts fall inside the error bands and the predicted error is below 10% until six steps ahead. Above this horizon the forecast lose efficiency. Although the model performed quite well for some taxes, further efforts are required for others. Finally, the elasticity appears to have fluctuated below the unity or the majority of taxes.

Keywords: Brazilian gross tax burden; Dynamic linear model with parameter variable; Bayesian methods; Forecasting.

JEL classification: H20, H22, C32

* IPEA-Instituto de Pesquisa Econômica Aplicada. E-mail: mario.mendonca@hotmail.com

† IPEA-Instituto de Pesquisa Econômica Aplicada. E-mail: sachside@hotmail.com

‡ IPEA-Instituto de Pesquisa Econômica Aplicada. E-mail: lmedrano10@msn.com

1 Introdução

O objetivo do trabalho é modelar econometricamente o comportamento da carga tributária bruta brasileira (CTBB), com base no comportamento individual de um conjunto de tributos¹ existentes na economia brasileira que formam uma amostra fortemente representativa da CTBB no período de 1995 a 2010. Essa amostra pode ser entendida como uma proxy da CTBB, uma vez que responde por cerca de 80% da arrecadação tributária no Brasil. A análise econométrica da CTBB, tendo em vista a avaliação de cada tributo tomado separadamente, vem dar continuidade a uma sequência de trabalhos já implementados no Brasil que têm como objetivo a análise e projeção da CTBB.

Os estudos implementados anteriormente seguiram dois caminhos distintos. Inicialmente, optou-se pela análise da CTBB segundo um ponto de vista agregado. Para tal, Mendonça et al. (2011) fizeram uso do modelo linear dinâmico (MLD) com coeficientes variáveis para uma série trimestral agregada da CTBB no período 1995-2009.² As principais conclusões deste estudo foram que: i) o produto interno bruto (PIB) é certamente a principal variável explicativa da dinâmica da CTBB no período em questão; ii) a elasticidade-PIB da CTBB parece estar próxima da unidade ou um pouco abaixo disso para duas as medidas do PIB real utilizadas; e, finalmente, iii) a parcela da CTBB autônoma em relação ao PIB teve crescimento relevante durante todo este último período, possivelmente indicando contínuas melhorias nos procedimentos de fiscalização adotados pelas autoridades tributárias e/ou aumentos na formalização da economia.

O outro tipo de abordagem, que aparece em Mendonça et al. (2009), se deu a partir da aplicação do modelo fatorial dinâmico (MFD) usando dados mensais para o período de 1995 a 2007. Uma razão fundamental para o uso do MFD é que este permite obter insights importantes por meio da redução de dimensionalidade (isto é, de aumento no grau de agregação) do modelo. Se, de algum modo, a informação contida nas inter-relações entre os vários tributos puder ser “passada para um conjunto menor de variáveis”, a habilidade de identificar a “verdadeira” estrutura dos dados será melhor.

Neste estudo, utiliza-se novamente o MLD para modelar as séries de alguns dos principais tributos individualmente. A utilização de um modelo com coeficientes variáveis (discutido, entre outros, por West & Harrison (1997)) é justificada pela conjectura — que parece muito plausível *a priori* — de que as sucessivas mudanças no sistema tributário nacional estão associadas a mudanças recorrentes também nas elasticidades relevantes, de modo a tornar contraindicado o uso de especificações com parâmetros fixos. A aplicação de modelos com coeficientes variáveis para a modelagem de séries tributárias não é inédita na literatura brasileira (ver, por exemplo, Hernández 1998, Portugal & Portugal 2001). Contudo, o presente estudo adiciona algumas contribuições à literatura sobre previsão de impostos no Brasil.

Primeiro, uma inovação do estudo é a opção por modelar o componente sazonal da série da CTBB endogenamente.³ Apesar de pouco usual na lite-

¹Os tributos formam a receita da União, estados e municípios e abrangem impostos, taxas, contribuições e empréstimos compulsórios. Por exemplo, o Imposto de Renda é um tributo, assim como Contribuição para o Financiamento da Seguridade Social (Cofins).

²A metodologia de construção da série da CTBB trimestral é apresentada em Santos & Costa (2008).

³Em geral, a maneira como se modela a sazonalidade é artificial e puramente ad hoc. O

ratura, tal procedimento permitiu obter estimativas significativamente mais ajustadas aos dados, assim como projeções mais confiáveis. Em segundo lugar, decidiu-se estimar o modelo a partir de procedimentos bayesianos (Gammerman & Lopes 2006, Kim & Nelson 1999, West & Harrison 1997), que, entre outras vantagens, permitem a obtenção de estimativas, em pequenas amostras, mais confiáveis que os métodos frequentistas (Gelman et al. 2003). Por fim, como já foi ressaltado, as séries de tributos foram modeladas separadamente, procedimento muito mais eficaz em termos práticos para fins de análise macroeconômica.

Os resultados obtidos vieram a corroborar a expectativa dos autores quanto à adequação dessa metodologia no caso dos tributos. No que se refere à previsão, doravante previsão condicional, os resultados foram bastante satisfatórios, mesmo se considerando o horizonte projetado de 12 meses fora da amostra no período de abril de 2009 a março de 2010. De um modo geral, verificou-se que os valores observados ficaram dentro do intervalo de confiança da projeção, e o erro de previsão foi de até 10% nos primeiros seis meses. A partir daí, a qualidade da projeção se deteriora.

Os modelos para o Imposto sobre Operações Financeiras (IOF), Previdência, Imposto sobre Circulação de Mercadorias e Prestação de Serviços (ICMS), Imposto de Renda de Pessoa Física (IRPF) e Imposto de Renda Total (IRT) mostraram excelentes resultados, enquanto demandam-se esforços posteriores para o Imposto sobre Produtos Industrializados (IPI) e o Programa de Integração Social/Programa de Formação do Patrimônio do Servidor Público (PIS/PASEP). Percebeu-se ainda que o método usado para tratar a sazonalidade gerou um alto grau de ajustamento no modelo. Apresenta-se ainda os valores encontrados para as elasticidades, que de um modo geral se mostraram abaixo da unidade.

Além desta introdução, o texto está estruturado da seguinte forma. A segunda seção tem como finalidade justificar a aplicação do modelo proposto com base nas características das séries individuais de tributos no Brasil. Na terceira seção, uma especificação econométrica e suas motivações teóricas são apresentadas, bem como a descrição dos dados utilizados. Detalhes sobre a metodologia econométrica utilizada foram acrescentados nos apêndices. Os resultados obtidos por meio desta especificação são apresentados e analisados na quarta seção. Por fim, a quinta seção traz breves notas à guisa de conclusão.

2 Justificativa

A carga tributária bruta⁴ de uma determinada economia é dada pela soma dos recursos que o governo recolhe compulsoriamente do setor privado. Tudo mais permanecendo constante, aumentos na carga tributária bruta brasileira

que comumente se faz é previamente dessazonalizar a série por algum método convencional e estimar o modelo usando a série modificada. Quanto a isso, existe um problema sério quando o assunto é previsão. A sazonalidade é uma característica idiossincrática de cada série de tributos, o que faz com que a sua não consideração certamente contribua para diminuir a qualidade do ajustamento e da previsão. Pode-se, naturalmente, introduzir novamente a sazonalidade ao se efetuar tal exercício. Entretanto, este é um processo mais custoso, com pouca garantia quanto ao seu resultado efetivo. Neste caso, os parâmetros que modelam a sazonalidade foram obtidos fora do modelo, isto é, não se levando em consideração a informação relevante. O método adotado neste estudo permite ultrapassar todas estas dificuldades, pois a sazonalidade é vista como sendo um conjunto de parâmetros a mais dentro do modelo.

⁴Para uma análise da composição da carga tributária no Brasil, ver Santos et al. (2008).

(CTBB) reduzem a renda disponível do setor privado e, portanto, os recursos disponíveis para o financiamento das despesas de consumo e investimento de famílias e firmas. No entanto, incrementos na CTBB aumentam, via de regra,⁵ os recursos à disposição do governo e, por conseguinte, permitem diminuições no nível de endividamento público e aumentos na oferta de bens e serviços públicos à população. Assim, a dinâmica da CTBB é um determinante crucial das dinâmicas de diversas outras grandezas macroeconômicas relevantes.

Embora pareça razoável — como primeira aproximação, pelo menos — supor que as arrecadações dos diferentes tributos que compõem a CTBB acompanhem o movimento geral da economia (ver, entre outros, Mendonça et al. 2008, Santos et al. 2008), é fácil perceber que as heterogeneidades existentes entre os mesmos fazem com que os resultados de modelos agregativos sejam usualmente pouco precisos. No entanto, as seguidas mudanças na legislação tributária,⁶ fazem com que haja bons motivos para se supor que as elasticidades e sazonalidades possam variar com o tempo. Tais mudanças têm sido caracterizado a administração tributária do país no período pós-Plano Real.⁷ Não surpreende, pois, que a literatura brasileira com especificações econométricas explícitas para a CTBB e seus principais elementos seja relativamente pequena,⁸ e que os resultados relatados sejam frequentemente apenas exploratórios.

Assim, um modelo econométrico que objetive modelar os vários componentes da CTBB deve não apenas lidar com a alta dimensionalidade inerente aos variados tipos de impostos, mas também saber tratar as características sazonais específicas a cada um deles. Apenas de modo a mostrar a dificuldade inerente à modelagem econométrica da CTBB, ilustra-se nos gráficos 1, 2 e 3 a evolução de três importantes componentes seus, que são o IRPF, as receitas previdenciárias (RPs) e o PIS/PASEP. Observa-se que, embora o IRPF e as RPs apresentem padrões de sazonalidade bem comportados, eles não são iguais, pois enquanto a sazonalidade que aparece nas RPs se evidencia na forma de picos com base estreita, no caso do IRPF os picos ocorrem de forma semelhante, mas a base não é estreitada. Em relação ao PIS/PASEP, existe naturalmente um padrão de sazonalidade, embora não tão bem comportado como nos dois casos anteriores.

⁵Note-se que nem todo recurso recolhido compulsoriamente da sociedade pelo governo é receita do governo. As contribuições para o FGTS, para citar um exemplo, são recolhidas compulsoriamente da sociedade — e por isso entram no cálculo da CTBB —, mas não são receitas públicas, visto que são de propriedade dos trabalhadores. Por sua vez, nem toda receita do governo é recolhida compulsoriamente da sociedade. Quando um cidadão paga a entrada em um museu público, está aumentando a receita do governo, mas não a carga tributária. Daí que aumentos na carga tributária não necessariamente implicam aumentos nas receitas públicas, e aumentos nestas últimas não necessariamente implicam aumentos na carga tributária. No entanto, a maior parte das receitas públicas brasileiras é de natureza tributária e a maior parte da carga tributária brasileira consiste de receitas públicas.

⁶Rezende et al. (2008) fazem um excelente resumo das inúmeras mudanças na legislação tributária brasileira no período de 1998 a 2006

⁷E mesmo antes disso, como bem apontam Rezende et al. (2008).

⁸Santos et al. (2008) apresentam uma resenha da literatura relevante.

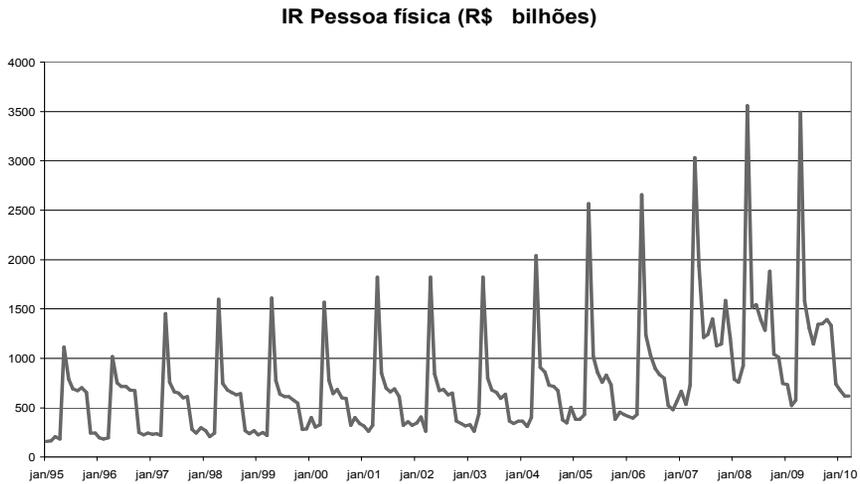


Figura 1: Evolução do IRPF (1995-2010)

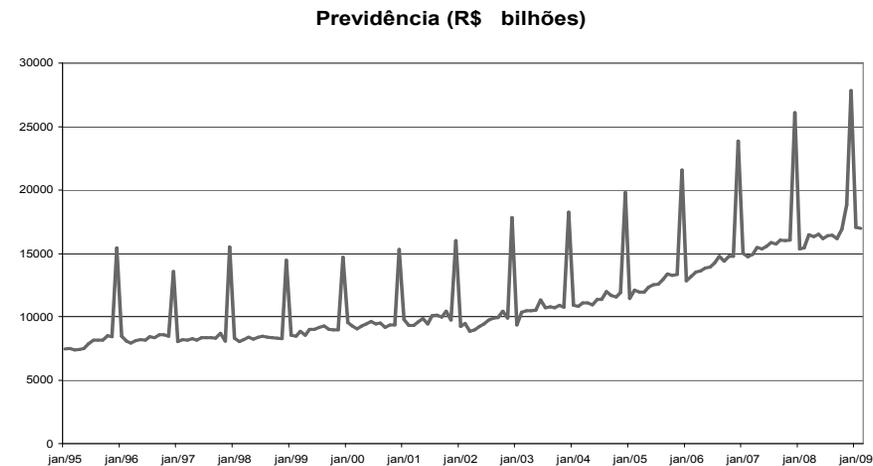


Figura 2: Evolução das RPS (1995-2009)

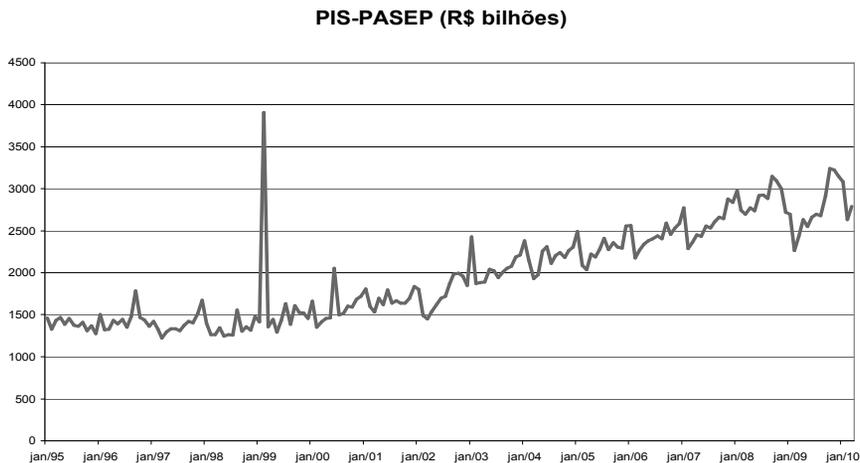


Figura 3: Evolução do PIS/PASEP (1995-2010)

3 Base de dados, aspectos gerais e metodologia

3.1 Base de dados

O objetivo aqui se refere ao tratamento individual de uma amostra formada por dez tributos fortemente representativos da CTBB. A Tabela 1 apresenta a amostra dos tributos usada neste estudo, bem como a porcentagem que cada um deles representa em relação ao total. A amostra é composta de nove tributos individuais, dos quais três são tributos incidentes sobre a renda, o patrimônio e o capital, a saber, o IRPF, o Imposto de Renda sobre Pessoa Jurídica (IRPJ) e o Imposto de Renda Retido na Fonte (IRRF). Quatro incidem sobre produtos: o ICMS, a Contribuição para o Financiamento da Seguridade Social (Cofins), IOF e o IPI. Integram ainda a amostra as seguintes contribuições previdenciárias: contribuição à Previdência Social e as contribuições para o PIS/PASEP. Em relação ao imposto de renda, há uma série agregada composta para os três impostos definidos.

A amostra se compõe basicamente de tributos federais, cuja base de dados é gerenciada pela Secretaria da Receita Federal (SRF), mas inclui também o ICMS, estadual - com dados mensais disponibilizados pelo Conselho Nacional de Política Fazendária (Confaz). Os dados de impostos federais advindos da Receita Federal utilizados neste estudo estão relacionados ao regime de competência e são livres de restituições, juros e refinanciamentos. Portanto, podem diferir dos dados disponibilizados pela Secretaria do Tesouro Nacional (STN).

Estes nove tributos representam aproximadamente 80% da receita bruta do total de tributos arrecadados pelas administrações públicas brasileiras. Os dados são mensais e se referem ao período de janeiro de 1995 a dezembro de 2010.

Tabela 1: Participação dos tributos no total da amostra (Em %)

Imposto		Imposto	
ICMS	26,52	IPI	5,39
Previdência Social	20,17	PIS/PASEP	5,38
Cofins	12,77	IOF	1,19
IRRF	10,66	IRPF	1,30
IRPJ	7,23	IRT (IRRF+IRPJ+IRPF)	19,19

Fonte: Elaboração dos autores.

3.2 Aspectos gerais

Dado o elevado número de tributos existentes no Brasil, a estimação da CTBB tributo a tributo,⁹ tal como é o objetivo deste estudo, se torna muito trabalhosa. O que em geral se costuma fazer é estimar um modelo agregativo para a CTBB tomando o PIB como proxy para os fatos geradores de todos os tributos brasileiros (Portugal & Portugal 2001, Hernández 1998, Santos et al. 2008, Mendonça et al. 2011). Naturalmente, espera-se que elevações e quedas no

⁹Mendonça et al. (2009) empregam o modelo fatorial dinâmico para modelar a arrecadação de impostos conjuntamente.

PIB real estejam associadas às elevações e quedas na arrecadação tributária real.

No caso da análise dos tributos tomados separadamente, está claro que a arrecadação de um determinado tributo depende positivamente tanto da alíquota quanto do montante do fato gerador. Dito de outro modo, é natural supor, por exemplo, que tudo mais permanecendo constante a arrecadação do IRPF deverá estar correlacionada, supostamente, com a massa salarial. Além disso, a arrecadação do IOF deve estar correlacionada com o volume das operações de crédito. Seguindo esse raciocínio, o IPI deverá ter como fato gerador a produção industrial. Na Tabela 2, associa-se cada tributo que compõe a amostra com as variáveis escolhidas como possíveis fatos geradores do respectivo imposto. A descrição das variáveis usadas como proxy para os fatos geradores dos impostos é feita a seguir.

1. PIB: Produto interno bruto deflacionado pelo Índice de Preços ao Consumidor Amplo (IPCA). Fonte: Banco Central do Brasil (BCB).
2. PIND: Índice do produto industrial. Fonte: Instituto Brasileiro de Estatística (IBGE).
3. Crédito: Operações de crédito feitas pelo setor privado. Fonte: BCB.
4. Ibovespa: Índice da Bolsa de Valores de São Paulo.
5. Massa salarial real: Massa de rendimentos nominal¹⁰ divulgada pela Pesquisa Mensal de Emprego (PME) deflacionada pelo IPCA. Fonte: IBGE.

A estratégia é partir de um modelo inicial e verificar se a ideia inicial dos autores deste estudo se ajusta aos dados. Apenas para antecipar, pode-se dizer que não necessariamente acontecerá que em todos os casos o projeto inicial dos autores será o que define melhor o comportamento do dado.

3.3 Especificação econométrica

Tendo em vista as considerações apresentadas, optou-se por iniciar a investigação econométrica com a especificação do modelo linear dinâmico que aparece na equação (1). A introdução da “constante” nesta especificação não é ingênua, porque, como visto na seção 2, pode-se supor que uma parcela da arrecadação do tributo pode ser autônoma — como aquela decorrente da tributação sobre o patrimônio, por exemplo —, e não relacionada a nenhum dos fatores descritos.¹¹

¹⁰A massa de rendimentos nominal, divulgada pela PME do IBGE e restrita a seis regiões metropolitanas, corresponde ao produto do rendimento médio efetivo do trabalho e da população ocupada remunerada, divulgado, igualmente, na PME. O cálculo da massa de rendimentos nominal, com abrangência nacional, consiste no produto da massa de rendimentos nominal divulgada na PME por um fator fixo, definido como a razão entre a massa de rendimentos divulgada pela Pesquisa Nacional por Amostra de Domicílios (PNAD, do IBGE) e a massa de rendimentos divulgada pela PME, em ambos os casos consideradas as médias dos meses de setembro (mesmo mês de referência da PNAD) de 2002 a 2008.

¹¹É interessante notar, no entanto, que o modelo supõe que o termo “constante” varia com o passar do tempo, por isso as aspas.

Tabela 2: Fatos geradores dos tributos

Tributo	Possíveis fatos geradores
IRT	Massa de salários, PIB, juros e Ibovespa.
IRPF	Massa de salários, PIB e Ibovespa.
IRPJ	PIB, juros e crédito.
IRRF	Massa de salários, PIB, juros e Ibovespa.
IPI	Produção industrial.
IOF	PIB e crédito.
ICMS	PIB.
RP	Massa de salários e PIB.
PIS/PASEP	PIB.

Fonte: Elaboração dos autores.

$$IMP_i(t) = \sum_{i=1}^n b_i(t) PFG_i(t) + S_i(t) + v_i(t) \quad (1)$$

$$b_i(t) = \varphi_i b_i(t-1) + w_i(t)$$

onde $IMP_i(t)$ representa o imposto i no período t , $PFG_i t$ a variável *proxy* para o fato gerador ou variável que gera a arrecadação do imposto, e n o número de fatos geradores. Ainda tem-se $w_i(t) \sim N(0, W_i)$, para $i = 0, \dots, 3$, enquanto φ_i é o componente autorregressivo da equação de estado para cada b_i . $S_i(t)$ é o componente sazonal, modelado de acordo com a representação de Fourier (West & Harrison 1997), tal como mostrada a seguir:

$$S_i(t) = \sum_{j=1}^2 \left[a_{ij} \sin\left(\frac{2\pi jt}{4}\right) + b_{ij} \cos\left(\frac{2\pi jt}{4}\right) \right] = Z_t \gamma_i$$

onde $Z_t = \left[\sin\left(\frac{2\pi t}{4}\right) \sin\left(\frac{2\pi 2t}{4}\right) \cos\left(\frac{2\pi t}{4}\right) \cos\left(\frac{2\pi 2t}{4}\right) \right]^T$ e $\gamma_i = (\gamma_{i1}, \gamma_{i2}, \gamma_{i3}, \gamma_{i4})$.

De modo a fazer com que as estimativas obtidas expressem os valores das elasticidades, empregou-se a transformação logarítmica. Deve-se atentar para o fato de que a previsão dos tributos foi feita tendo em vista o conhecimento prévio das variáveis exógenas no horizonte de previsão, o que não ocorre em uma situação real em que se deseja fazer a previsão para o futuro. Assim, uma designação mais apropriada seria nomear esse procedimento como um exercício de projeção condicional. Nesse caso, teriam de ser previstas ou projetadas as variáveis exógenas antes de serem incorporadas ao modelo de previsão condicional dos impostos que aparece em (1), o que gera mais uma fonte de incerteza. Mendonça et al. (2009) perfazem um exercício interessante de previsão não condicional para impostos individuais usando o modelo fatorial dinâmico.

Deve-se ressaltar que o procedimento bayesiano adotado para a estimação do modelo DLM elimina o problema da ordem de integração das séries, bem como diminui a relevância do tamanho da amostra. Diversos autores (Dejong & Whiteman 1991, Koop 1992, Sims & Uhlig 1991) advogam vigorosamente em favor da alternativa bayesiana sobre a abordagem clássica mais tradicional usada no que se refere à questão da raiz unitária. Por exemplo, sabe-se que os testes do tipo Dickey-Fuller aumentado (ADF) são de baixa potência frente

a alternativas plausíveis, especialmente em relação à hipótese alternativa de tendência estacionária. A abordagem bayesiana, por sua vez, revelaria que as hipóteses de raiz unitária e de tendência estacionária apresentariam probabilidades bastante similares quanto às suas funções a posteriori. Assim, a abordagem bayesiana fornece um sumário mais razoável da informação amostral que a abordagem clássica.

Outro problema com os testes clássicos de raiz unitária é a descontinuidade gerada na teoria assintótica (Sims & Uhlig 1988). A abordagem bayesiana, por ser baseada na função de distribuição a posteriori, não apresenta o problema da descontinuidade. Koop (1992) assinala que na abordagem clássica os valores críticos gerados a partir de pequenas amostras podem diferir substancialmente dos valores críticos assintóticos. A abordagem bayesiana, visto que é condicional à amostra observada, fornece resultados mais exatos para pequenas amostras. Em resumo, o problema da raiz unitária não é um ponto crítico na estatística bayesiana.

Por fim, diferentemente da abordagem clássica, a prática bayesiana não é dependente do teorema central do limite, o que elimina o uso de propriedades assintóticas (Gelman et al. 2003, pag.696). Isso traz uma importante vantagem em termos da habilidade de obter estimativas mais confiáveis em um contexto de pequenas amostras e alta dimensionalidade paramétrica. Esse ponto é fundamental no caso brasileiro, no qual séries de variáveis macroeconômicas realmente confiáveis somente estão disponíveis a partir do aparecimento do Plano Real em 1994.

4 Resultados

Nesta seção são apresentados os resultados da estimação do modelo definido pela equação com base na prática bayesiana. O procedimento bayesiano utilizado para estimar o modelo econométrico é relativamente complexo. É interessante ressaltar que, até onde se sabe, nos casos em que o procedimento frequentista foi aplicado (Portugal & Portugal 2001, Hernández 1998, Santos et al. 2008), os parâmetros do modelo eram regidos forçosamente por um passeio aleatório. Neste artigo, há um processo autorregressivo para cada parâmetro do modelo, tal como pode ser visto na equação (1), o que torna a forma de abordagem menos restrita. Uma descrição sucinta acerca da implementação do modelo é feita no Apêndice A.

Cada imposto foi inicialmente modelado usando as variáveis explicativas apresentadas na Tabela 2, o que não significou naturalmente que o melhor modelo encontrado apresente este mesmo conjunto de regressores, sendo que a seleção do melhor modelo foi feita em cada um dos modelos com base no critério EQM¹² de seleção de modelos que avalia a projeção, no caso, condicional fora da amostra. No que diz respeito à escolha do critério EQM, na verdade a literatura econométrica não dispensa muita discussão acerca da escolha do melhor critério de seleção de modelos quando o objetivo específico se trata de checar a performance do modelo fora da amostra, ou seja, quando o objetivo é previsão. Diferentemente, existem diversos critérios concorrentes

¹²Erro quadrado médio $EQM = N^{-1} \sum_{i=1}^N e_i^2$.

quando o propósito é avaliar o desempenho do modelo dentro da amostra.¹³ Em geral, o critério EQM é comumente mencionado na literatura econométrica teórica (Stock & Watson 2007, Ltkepohl 2007, Hamilton 1994) quando o objetivo específico é checar a capacidade preditiva do modelo, sendo que diversos estudos empíricos fazem uso deste critério com a mesma finalidade (Carvalho & Minella 2009, Lima & Alves 2011).

Uma justificativa para a aplicação do EQM está relacionada ao fato de que isso não estaria em contradição com o emprego da previsão condicional como preditor, na medida em que o EQM aponta como melhor preditor a esperança condicional. Em outras palavras, a esperança condicional é o melhor preditor quando o valor esperado do EQM é minimizado.

No Apêndice B, é possível saber qual o modelo que foi estimado. Por exemplo, o IRT foi estimado inicialmente usando quatro regressores de acordo com a Tabela 2: a massa salarial, os juros, o PIB e o IBOVESPA. Contudo, o critério de seleção EQM apontou que o melhor modelo é o que utiliza apenas o PIB como variável explicativa. Assim, pode-se dizer que nem sempre a intuição dos autores quanto à variável representativa do fato gerador se mostrou correta. Nos dois casos em que foi utilizada, a massa salarial real não atendeu às expectativas quanto a sua capacidade como fato gerador para os respectivos tributos. Isso aconteceu também quanto ao IRPF, IRRF e RP. Não obstante, deve-se levar em consideração que os dados para essa variável estão disponíveis somente a partir de 2004, o que fez com que os resultados da estimação nos casos em que essa variável era usada como regressor ficassem fortemente prejudicados. A Tabela 3, a seguir, explicita os modelos que foram realmente estimados.

Tabela 3: Modelos estimados

Tributo	Fatos geradores
IRT	PIB
IRPF	PIB e Ibovespa
IRPJ	PIB e juros
IRRF	PIB e juros
IPI	Produção industrial
IOF	PIB
ICMS	PIB
RP	PIB
PIS/PASEP	PIB

Fonte: Elaboração dos autores.

Devido ao elevado número de tributos tratados neste estudo, e de modo a facilitar o entendimento, todos os resultados foram remetidos aos apêndices no final do texto. Os modelos foram estimados com dados para o período de janeiro de 1995 a março de 2009, enquanto as projeções condicionais foram feitas 12 passos à frente para o período de abril de 2009 a março de 2010. Os resultados estão postos da seguinte forma. No Apêndice B, apresentam-se os gráficos das elasticidades. Ressalte-se que, por economia, não se apresentaram

¹³Os critérios de Informação de Akaike, Teste de razão de verossimilhança, Hannan-Quinn e Schwarz Bayesiano são exemplos de critérios de escolha de modelos dentro da amostra (Ltkepohl 2007)

os gráficos referentes aos interceptos.¹⁴ O Apêndice C contém os gráficos com as previsões. As Tabelas contendo os valores projetados, bem como erros de previsão, aparecem no Apêndice D. Por fim, os gráficos para ajustamento do modelo são apresentados no Apêndice E.

Observando-se os resultados do Apêndice E, percebe-se que as variáveis em questão têm uma forte estrutura sazonal que não pode ser ignorada na análise. Com efeito, nota-se que o método usado para tratar a sazonalidade gerou um alto grau de ajustamento na série de cada variável. Em relação aos resultados propriamente ditos, alguns merecem destaque. De forma geral, no que tange à previsão, os resultados apresentaram um bom desempenho. Dado que o horizonte em que esta foi implementada se deu para um número relativamente grande de passos à frente, espera-se naturalmente que nos períodos finais a qualidade da previsão decaia.

De um modo geral, pode-se verificar que os valores observados ficaram dentro do intervalo de confiança da projeção, e o erro de previsão foi de até 10% nos primeiros seis meses. A partir daí, a qualidade da projeção se deteriora. Os modelos para IOF, Previdência, ICMS, IRPF e IRT mostraram excelentes resultados, ao passo que para outros, como o IPI e o PIS/PASEP, demandam-se esforços posteriores. Percebeu-se ainda que o método usado para tratar a sazonalidade gerou um alto grau de ajustamento no modelo. Apresentam-se ainda os valores encontrados para as elasticidades, que de modo geral se mostraram abaixo da unidade.

Por fim, serão feitos alguns comentários pontuais sobre as elasticidades obtidas. Tendo em vista o comportamento das trajetórias observadas para as elasticidades, nas quais se observam mudanças contínuas em quase todos os casos, verifica-se que foi acertada a opção de se modelarem as séries individuais dos impostos a partir da aplicação do modelo linear com parâmetros variáveis. Como foi colocado na introdução deste estudo, a ideia de usar essa metodologia tem por base o fato de que o sistema tributário brasileiro foi inundado por sucessivas mudanças que poderiam ter reflexo nas elasticidades, o que faria ser não aconselhável o emprego de uma especificação com parâmetros fixos.

5 Conclusões

Neste estudo, utiliza-se o modelo linear dinâmico com parâmetros variáveis a fim de se modelarem as séries individuais para uma amostra representativa de tributos que integram a carga tributária bruta brasileira (CTBB). Os resultados obtidos corroboraram a expectativa dos autores quanto à aplicação dessa metodologia, tendo em vista que as sucessivas mudanças no sistema tributário nacional estão associadas a mudanças recorrentes também nas elasticidades relevantes, de modo a tornar contraindicado o uso de especificações com parâmetros fixos.

Também considerando-se que as séries dos tributos possuem forte sazonalidade, específica para cada um deles, percebeu-se que o método usado para tratar a sazonalidade gerou um alto grau de ajustamento na série de cada variável. De uma forma geral, no que concerne à previsão dita condicional, os resultados apresentaram um bom desempenho, devendo-se levar em conta

¹⁴Estes podem ser obtidos diretamente com os autores.

ainda o horizonte projetado de 12 meses. Observou-se, entretanto, que a qualidade da previsão mostra uma deterioração acentuada quando o horizonte se situa acima de seis meses. Assim, mais esforços são necessários para aprimorar a eficiência da previsão, caso se tenha necessidade de conhecer o comportamento futuro das séries da maioria dos impostos para um horizonte futuro mais distante que cinco ou seis meses.

Referências Bibliográficas

- Carter, C. K. & Kohn, R. (1994), 'On gibbs sampling for state space models', *Biometrika* **81**(3), 541–553.
- Carvalho, F. A. & Minella, A. (2009), Market forecasts in brazil: performance and determinants, Working Papers Series 185, Central Bank of Brazil, Research Department.
- Dejong, N. & Whiteman, C. H. (1991), 'The case for trend-stationarity is stronger than we thought', *Journal of Applied Econometrics* **6**(4), 413–421.
- Frúwirth-Schnatter, S. (1994), 'Data augmentation and dynamic linear models', *Journal of Time Series Analysis* **15**, 183–202.
- Gamerman, D. & Lopes, H. (2006), *Markov Chain Monte Carlo: Stochastic Simulation for Bayesian Inference*, New York: Chapman & Hall / CRC.
- Gelman, A., Carlin, J. B., Stern, H. S. & Rubin, D. B. (2003), *Bayesian Data Analysis*, Chapman and Hall/CRC; 2 edition.
- Hamilton, J. D. (1994), *Time series analysis*, Princeton Univ. Press, Princeton, NJ.
- Hérmendez, B. (1998), 'Um modelo econométrico da conta corrente do governo no brasil: 1951/95', (543).
- Kim, C. J. & Nelson, C. R. (1999), *State-Space Models with Regime Switching: Classical and Gibbs-Sampling Approaches with Applications*, The MIT Press.
- Koop, G. (1992), 'objective' bayesian unit root tests', *Journal of Applied Econometrics* **7**(1), 65–82.
- Lima, E. & Alves, P. (2011), O desempenho do mercado (focus) na previsão da inflação: Novos resultados?, Discussion Papers 1621, Instituto de Pesquisa Econômica Aplicada - IPEA.
- Ltkepohl, H. (2007), *New Introduction to Multiple Time Series Analysis*, Springer Publishing Company, Incorporated.
- Mendonça, M. J. C., Pires, M. C. C. & Medrano, L. A. T. (2008), 'Administração e sustentabilidade da dívida pública no brasil: Uma análise para o período 1996-2007', *Pesquisa e Planejamento Econômico* **38**, 389–411.
- Mendonça, M. J., Sachsida, A. & Medrano, L. A. T. (2011), 'Um modelo econométrico com parâmetros variáveis para carga tributária bruta trimestral', *Pesquisa e Planejamento Econômico* **41**(1), 133–162.

Mendonça, M. J., Santos, C. H. & Martins, T. G. (2009), Aplicação de um modelo fatorial dinâmico para previsão da arrecadação tributária no Brasil, Discussion Papers 1453, Instituto de Pesquisa Econômica Aplicada - IPEA.

Portugal, C. & Portugal, M. (2001), 'Os efeitos da inflação sobre o orçamento do governo: uma análise empírica', *Estudos Econômicos* 31(2), 239–283.

Rezende, F., de Oliveira, F. A. & Araujo, E. A. (2008), *O dilema fiscal: remendar ou reformar?*, Editora FGV.

Santos, C. H. M. & Costa, F. R. (2008), 'Uma metodologia de estimação da carga tributária bruta brasileira em níveis trimestrais', *Economia Aplicada* 12(4), 581–606.

Santos, C. H. M., Ribeiro, M. B. & Gobetti, S. W. (2008), A evolução da carga tributária bruta brasileira no período 1995-2007: Tamanho, composição e especificações econométricas agregadas, Discussion Papers 1350, Instituto de Pesquisa Econômica Aplicada - IPEA.

Sims, C. A. & Uhlig, H. (1988), 'Bayesian skepticism on unit root econometrics', *Journal of Economic Dynamics and Control* 12(2-3), 463–474.

Sims, C. A. & Uhlig, H. (1991), 'Understanding unit rooters: A helicopter tour', *Econometrica* 59(6), 1591–1599.

Stock, J. H. & Watson, M. W. (2007), *Introduction to Econometrics: Brief Edition*, Addison-Wesley Series in Economics, Pearson Addison Wesley.

West, M. & Harrison, J. (1997), *Bayesian forecasting and dynamic Models.*, Springer.

Apêndice A A metodologia de estimação utilizada neste trabalho

A.1 Modelo de regressão linear dinâmico

A forma geral do modelo DLM (dynamic linear model) pode ser definida da seguinte forma:

$$y_t = X_t \theta_t + S_t + v_t' \quad (2)$$

$$\theta_t = \Gamma_1 \theta_{t-1} + \dots + \Gamma_p \theta_{t-p} + \omega_t' \quad (3)$$

onde y_t é a variável endógena e X_t é um vetor $k \times 1$ de variáveis exógenas. Este modelo permite ainda a presença de um componente sazonal, S_t , que pode ser modelado segundo a representação do tipo de Fourier (West & Harrison 1997), de modo que

$$S(t) = \sum_{j=1}^2 \left[a_j \sin\left(\frac{2\pi jt}{4}\right) + b_j \cos\left(\frac{2\pi jt}{4}\right) \right] = Z_t \varphi$$

onde $Z_t = \left[\sin\left(\frac{2\pi t}{4}\right) \sin\left(\frac{2\pi 2t}{4}\right) \cos\left(\frac{2\pi t}{4}\right) \cos\left(\frac{2\pi 2t}{4}\right) \right]^T$ e $\varphi = (a_1, a_2, b_1, b_2)$.

Sendo θ_t o vetor $k \times 1$ de parâmetros que segue um processo autorregressivo de ordem p , em que os coeficientes estão contidos na matriz diagonal Γ_i , $k \times k$, para $i = 1, \dots, p$. Supõe-se que $\omega_t' \sim N(0_{k \times 1}, W_{k \times k})$ e $v_t' \sim N(0, V)$, admitindo-se ainda que ω_t' e v_t' não são correlacionados. Por simplicidade, admite-se também que $W = \text{diag}(w_1, \dots, w_k)$.

A ideia da aplicação da forma de Fourier para tratar sazonalidade está ligada ao fato de que qualquer padrão cíclico pode ser representado em termos da combinação linear de funções periódicas.¹⁵ Outra motivação para o uso dessa abordagem, além da flexibilidade, é a facilidade de se obter interpretação, já que as trajetórias em forma de ondas podem ser associadas aos variados padrões observados na prática. Mais uma forma de tratar a sazonalidade seria introduzi-la diretamente na equação de estado. Nesse caso, a equação 2 assumiria a seguinte forma:

$$\theta_t = \Gamma_1 \theta_{t-1} + \dots + \Gamma_p \theta_{t-p} + S_t + \omega_t' \quad (4)$$

Por fim, a sazonalidade pode tomar uma forma dinâmica. Nesse caso, seria possível ter-se um modelo no qual a equação da medida é dada da seguinte forma:

$$y_t = F_t \theta_t^* + v_t'$$

onde $F = [X_t, Z_t]$ e $\theta_t^* = [\theta_t, \varphi_t]$.

Será feito agora uso da seguinte notação para encaixar as equações em uma forma mais compacta, que reduz o sistema expresso pelas equações (2) e (3) em uma forma de espaço-estado de ordem um:

$$\underline{\theta}_t = \begin{bmatrix} \theta_t \\ \theta_{t-1} \\ \vdots \\ \theta_{t-p+1} \end{bmatrix}_{kp \times 1}, \quad G = \begin{bmatrix} \Gamma_1 & \Gamma_2 & \dots & \Gamma_{p-1} & \Gamma_p \\ I_k & 0 & \dots & 0 & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & \dots & I_k & 0 \end{bmatrix}_{kp \times kp},$$

¹⁵Uma função $g(t)$ é dita periódica se, para algum inteiro $p > 1$, e todo $n, t > 0$, tem-se que $g(t + np) = g(t)$.

$$\underline{\omega}_t = \begin{bmatrix} \omega_t \\ 0 \\ \vdots \\ 0 \end{bmatrix}_{kp \times 1} \quad \text{e} \quad F'_t = \begin{bmatrix} X'_t \\ 0 \\ \vdots \\ 0 \end{bmatrix}_{kp \times 1} .$$

Visto isso, tem-se que:

$$y_t = F_t \underline{\theta}_t + Z_t \varphi + v'_t \tag{5}$$

$$\underline{\theta}_t = \Gamma \underline{\theta}_{t-1} + \omega'_t \tag{6}$$

onde (3.1) representa a equação da medida ou do movimento, enquanto (3.2) define a equação de estado.

A função de verossimilhança de (θ, G, ω, V) é dada por

$$p(y|\theta, G, \varphi, V) = (2\pi)^{(-\frac{T}{2})} V^{\frac{T}{2}} \exp\left(-\frac{1}{2V} \sum_{t=1}^T (y_t - F_t \underline{\theta}_t - z_t \omega)^2\right)$$

onde $y = (y_1, \dots, y_T)$, $\theta = (\underline{\theta}_1, \dots, \underline{\theta}_T)$ e $\Gamma = (\Gamma_1, \dots, \Gamma_p)$.

A.2 Procedimento de inferência

Nesta seção, é realizado um procedimento de inferência baseado no paradigma bayesiano. Inicialmente, apresentam-se distribuições *a priori* para todos os parâmetros. Em seguida, o algoritmo MCMC é utilizado para obter amostras a posteriori de todos os parâmetros do modelo.

Distribuição a priori

Por simplicidade, distribuições *a priori* conjugadas são utilizadas para todos os parâmetros. A distribuição *a priori* para θ_t é especificada na equação (3.2) e completada pela informação inicial θ_0 tal que $\theta_0 \sim N(m_0, C_0)$, onde m_0 e C_0 são hiperparâmetros conhecidos. As distribuições *a priori* para os parâmetros V, W, Γ e ω são as seguintes: i) $V \sim GI\left(\frac{n_V}{2}, \frac{n_V S_V}{2}\right)$; ii) $w_j \sim GI\left(\frac{n_W}{2}, \frac{n_W S_W}{2}\right)$ $j = 1, \dots, k$; iii) $\Gamma_j \sim N(m_{\Gamma}, S_{\Gamma})$, $j = 1, \dots, p$; e iv) $\omega \sim N(m_{\varphi}, S_{\varphi})$, onde $n_V, S_V, n_W, S_W, m_{\Gamma}, S_{\Gamma}, m_{\varphi}$, e S_{φ} são hiperparâmetros conhecidos. Os valores dos hiperparâmetros utilizados foram os seguintes: $m_0 = 0, C_0 = 100, n_V = 2, n_V S_V = 0.1, n_W = 2, n_W S_W = 0.1, m_{\Gamma} = 0, S_{\Gamma} = 100, m_{\varphi} = 0$ e $S_{\varphi} = 100$

Inferência a posteriori

A distribuição a posteriori conjunta de $(\theta, \Gamma, \varphi, V, W)$ é dada por

$$p(\theta, G, \varphi, V, W) \propto \prod_{t=1}^T p(y_t | \underline{\theta}_t, \varphi, V) \prod_{t=1}^T p(\underline{\theta}_t | \underline{\theta}_{t-1}, W, G) p(\underline{\theta}_0 | m_0, C_0) p(\varphi) p(V) p(W) p(\Gamma)$$

a qual é analiticamente intratável e, por conseguinte, a inferência a posteriori exata é feita utilizando-se o esquema MCMC. Nesse caso, o vetor da variável de estado é amostrado conjuntamente, utilizando-se o algoritmo FFBS

(forward filtering backward sampling) de Carter & Kohn (1994) e Frúwirth-Schnatter (1994). Para o resto dos parâmetros Γ, φ, V e W , todas as distribuições condicionais completas são distribuições normais ou distribuições gama inversa. Todas as distribuições condicionais completas estão listadas a seguir.

a) A distribuição condicional de V é

$$(V|\theta, W, \varphi, \Gamma) \sim GI\left(\frac{n_V^*}{2}, \frac{n_V^* S_V^*}{2}\right)$$

$$\text{onde } n_V^* = n_V + T \text{ e } n_V^* S_V^* = N_V S_V + \sum_{t=1}^T (y_t - F_t \underline{\theta}_t - z_t \varphi)^2$$

b) A distribuição condicional de $W = \text{diag}(w_1, \dots, w_k)$ é

$$(w_j|\theta, V, \varphi, \Gamma) \sim GI\left(\frac{n_W^*}{2}, \frac{n_W^* S_W^*}{2}\right)$$

$$\text{para } j = 1, \dots, k, \text{ onde } n_W^* = n_W + T - 1 \text{ e } n_W^* S_W^* = n_W S_W + \sum_{t=2}^T (\underline{\theta}_t - G \underline{\theta}_{t-1})^T (\underline{\theta}_t - G \underline{\theta}_{t-1}).$$

c) A distribuição condicional de $\Gamma = (\Gamma_1, \dots, \Gamma_p)$ é

$$(\Gamma_j|\theta, V, W, \varphi) \sim N(m_{\Gamma}^*, S_{\Gamma}^*)$$

$$\text{para } j = 1, \dots, k \text{ onde } S_{\Gamma}^* = (S_{\Gamma}^{-1} I_{p \times p} + w_j^{-1} H_j^T H_j)^{-1} \text{ e } m_{\Gamma}^* = S_{\Gamma}^{*-1} (S_{\Gamma}^{-1} I_{p \times p} 1_p + w_j^{-1} B_j^T H_j) \text{ para}$$

$$H_j = \begin{pmatrix} \theta_{p,j} & \theta_{p-1,j} & \cdots & \theta_{1,j} \\ \theta_{p+1,j} & \theta_{p,j} & \cdots & \theta_{2,j} \\ \vdots & \vdots & \vdots & \vdots \\ \theta_{T-1,j} & \theta_{T-2,j} & \cdots & \theta_{T-p,j} \end{pmatrix} \text{ e } B_j = \begin{pmatrix} \theta_{p+1,j} \\ \theta_{p+2,j} \\ \vdots \\ \theta_{T,j} \end{pmatrix}.$$

d) A distribuição condicional de φ é

$$(\varphi|\theta, V, W, \Gamma) \sim N(m_{\varphi}^*, S_{\varphi}^*)$$

$$\text{onde } S_{\varphi}^* = (S_{\varphi}^{-1} I_{4 \times 4} + V^{-1} Z^T Z)^{-1} \text{ e } m_{\varphi}^* = S_{\varphi}^{*-1} (S_{\varphi}^{-1} I_{4 \times 4} 1_4 + V^{-1} Z^T (y - F \theta)).$$

Os estados $\theta_1, \dots, \theta_T$ são amostrados conjuntamente, utilizando-se o algoritmo FFBS, condicional sobre Γ, φ, V e W . A distribuição condicional completa conjunta segue a decomposição retrospectiva

$$p(\theta|y) = p(\theta_T|D_T) \prod_{t=1}^{T-1} p(\theta_t|\theta_{t+1}, D_t)$$

onde $D_T = \{y_1, y_2, \dots, y_T\}$, $t = 1, \dots, T$ e D_0 representam a informação inicial. Iniciando com $\theta_0 \sim N(m_0, C_0)$, através do Filtro de Kalman pode ser mostrado que $\theta_t|D_t \sim N(m_t, C_t)$, onde $m_t = a_{t-1} + A(y_t - f_t - z_t \varphi)$, $C_t = R_t - A_t Q_t A_t'$, $a_t =$

$Gm_{t-1}, R_t = GC_{t-1}G' + W, f_t = F_t'a_t + z_t\varphi, Q_t = F_t'R_tF_t + V$ e $A_t = R_tF_tQ_t^{-1}$, para $t = 1, \dots, T$; θ_T é amostrado de $p(\theta_T|D_T)$ (passo denominado forward filtering). Para $t = T-1, T-2, \dots, 2, 1$, θ_t é amostrado de $(\theta_t|\theta_{t+1}, D_t) \sim N(\tilde{a}_t, \tilde{C}_t)$, onde $\tilde{a}_t = m_t + B_t(f_{t+1} - a_{t+1})$, e $B_t = C_tG'R_{t+1}^{-1}$ (passo denominado backward sampling).

Previsão modelo de regressão linear dinâmico

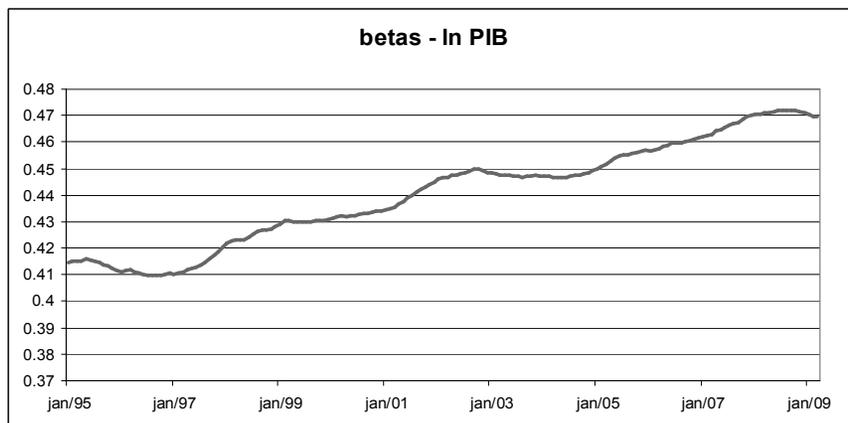
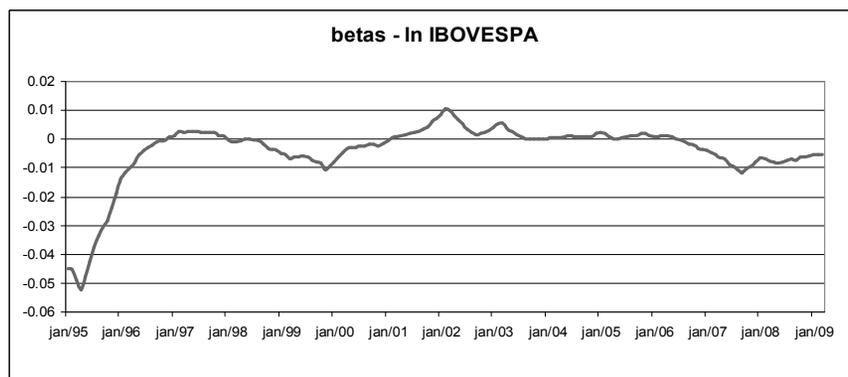
Fazer previsão nesta classe de modelos é teoricamente direto. Frequentemente, surge o interesse de aprender a densidade preditiva h passos a frente, $p(y_{T+h}|y)$, ou seja

$$p(\theta, G, \varphi, V, W) \propto \prod_{t=1}^T p(y_t|\underline{\theta}_t, \varphi, V) \prod_{t=1}^T p(\underline{\theta}_t|\underline{\theta}_{t-1}, W, G) p(\underline{\theta}_0|m_0, C_0) p(\varphi) p(V) p(W) p(\Gamma)$$

onde $(y_{T+h}|\underline{\theta}_{T+h}, \varphi, V) \sim N(F_{T+h}, V)$, $(\underline{\theta}_{T+h}|\underline{\theta}_T, W, \Gamma) \sim N(\mu_h, V_h)$, $\mu_h = G^h\underline{\theta}_T$ e $V_h = \sum_{j=1}^h G^{j-1}W(G^{j-1})'$, para $h > 0$. Portanto, se

$$\{(\underline{\theta}_T^1, \varphi^1, V^1, W^1, \Gamma^1), \dots, (\underline{\theta}_T^L, \varphi^L, V^L, W^L, \Gamma^L)\}$$

é uma amostra de $p(\underline{\theta}_t, W, \Gamma, V|y)$, é fácil amostrar $\underline{\theta}_{T+h}^j$ de $p(\underline{\theta}_{T+h}|\underline{\theta}_T^j, W^j, \Gamma^j)$, para todo $j = 1, \dots, L$, tal que $p(y_{T+h}|y) = \frac{1}{L} = \sum_{j=1}^L p(y_{T+h}|\underline{\theta}_{T+h}^j, \varphi^j, V^j)$ é a aproximação via Monte Carlo de $p(y_{T+h}|y)$. Analogamente, se y_{T+h}^j é amostrado de $p(y_{T+h}|\underline{\theta}_{T+h}^j, \varphi^j, V^1)$, para $j = 1, \dots, L$, então $\{y_{T+h}^1, \dots, y_{T+h}^L\}$ representa uma amostra de $p(y_{T+h}|y)$.

Apêndice B Gráficos das elasticidades**Figura B.1:** Média a posteriori de β_1 (ln PIB) para IRT**Figura B.2:** Média a posteriori de β_1 (ln IBOVESPA) para imposto de renda — pessoa física

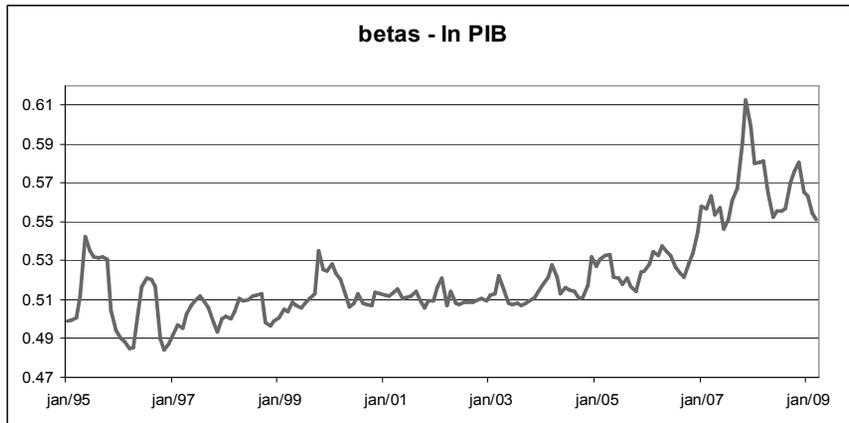


Figura B.3: Média a posteriori de β_2 (ln PIB) para imposto de renda — pessoa física

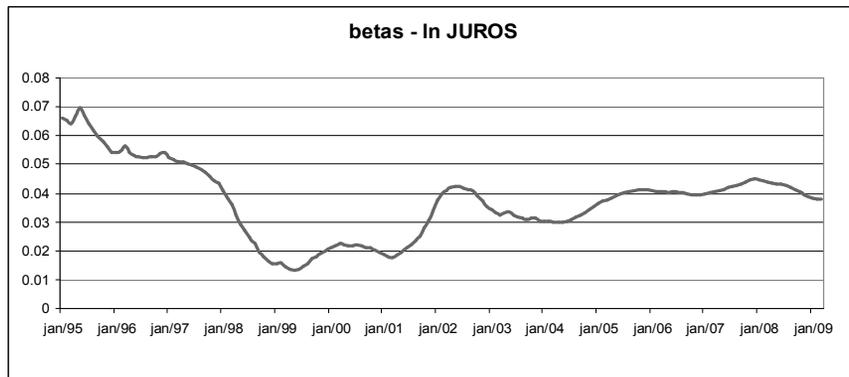


Figura B.4: Média a posteriori de β_1 (Juros) para imposto de renda — pessoa jurídica

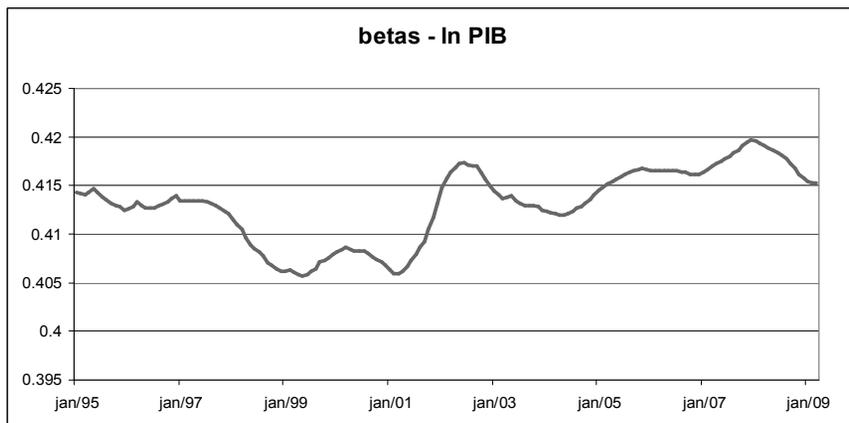


Figura B.5: Média a posteriori de β_2 (ln PIB) para imposto de renda — pessoa jurídica

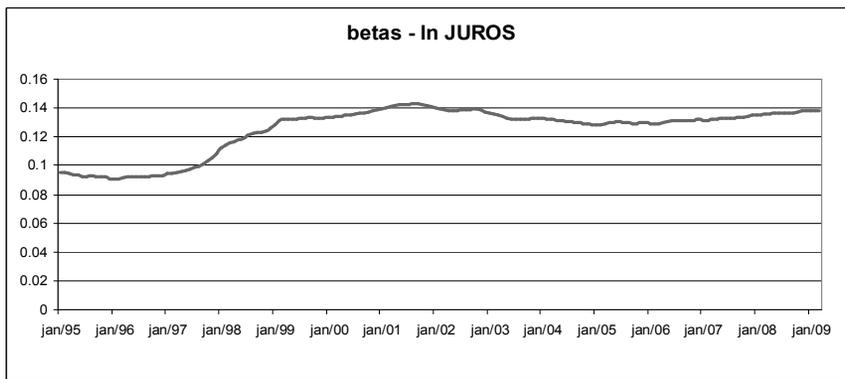


Figura B.6: Média a posteriori de β_1 (Juros) para imposto de renda — Retido na fonte

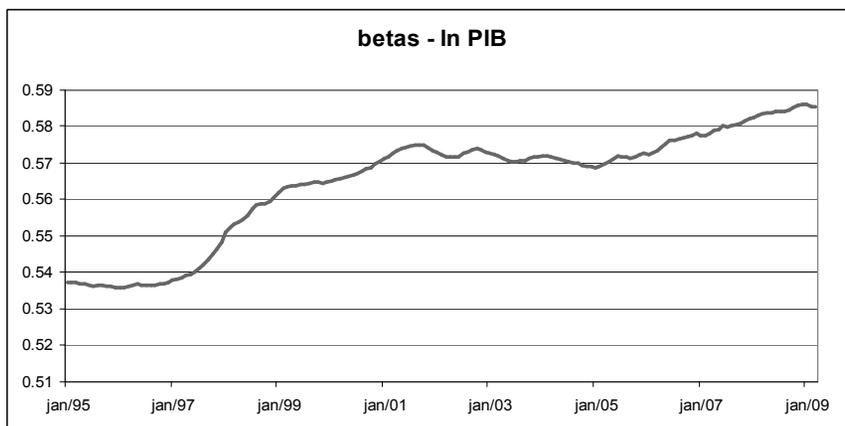


Figura B.7: Média a posteriori de β_2 (ln PIB) para imposto de renda — Retido na fonte

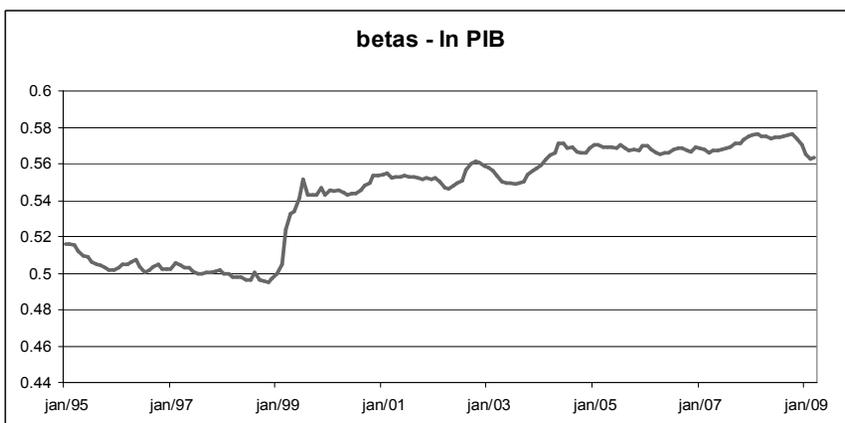


Figura B.8: Média a posteriori de β_1 (ln PIB) para COFINS

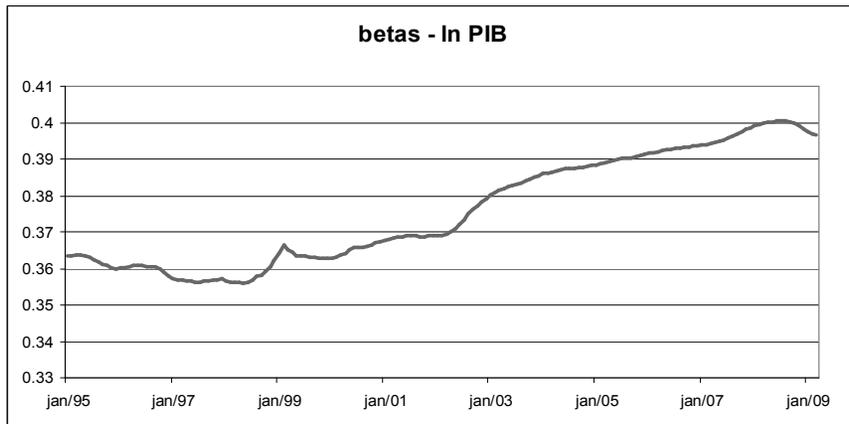


Figura B.9: Média a posteriori de β_1 (ln PIB) para PIS — PASEP

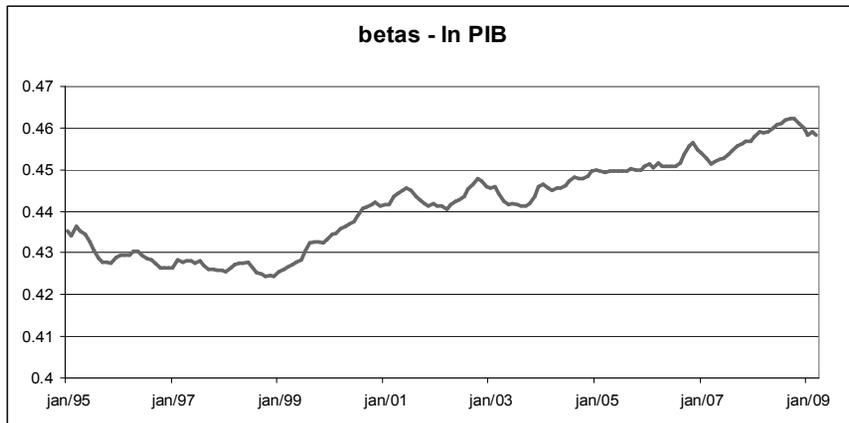


Figura B.10: Média a posteriori de β_1 (ln PIB) para ICMS

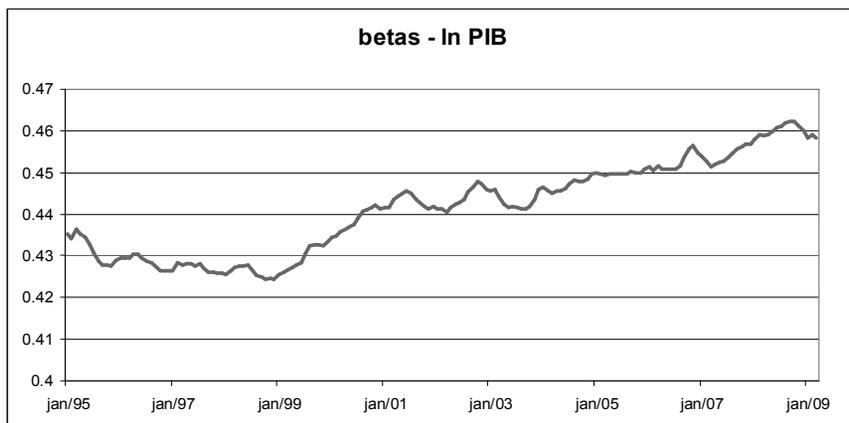


Figura B.11: Média a posteriori de β_1 (ln PIB) para Previdência

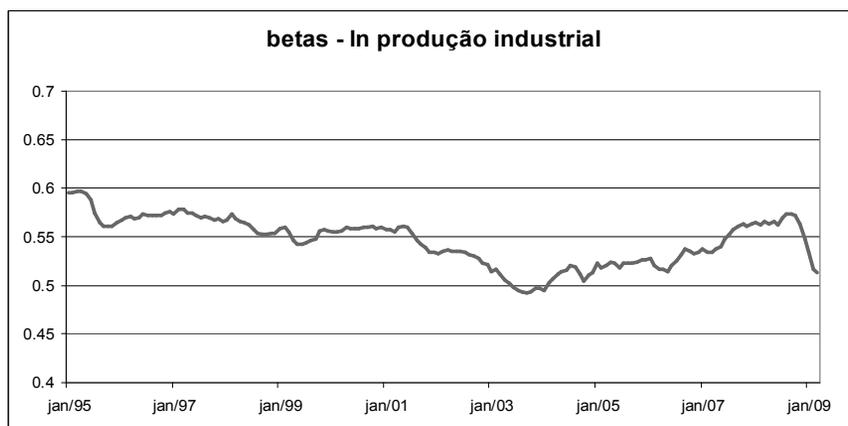


Figura B.12: Média a posteriori de β_1 (ln produção industrial) para IPI

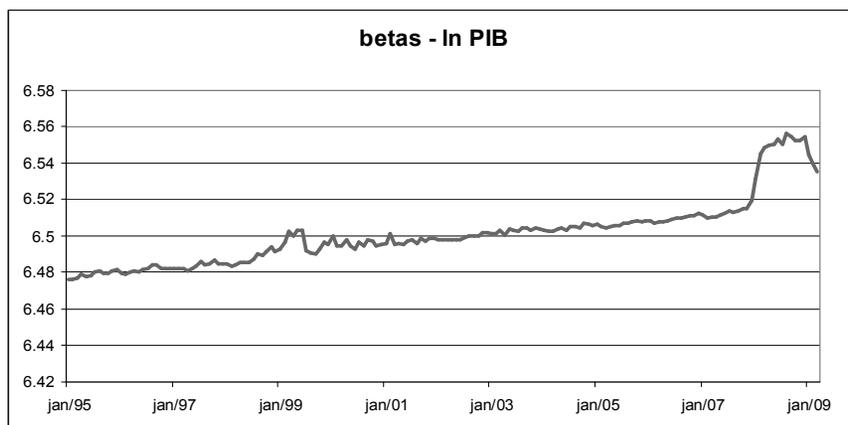


Figura B.13: Média a posteriori de β_1 (ln PIB) para IOF

Apêndice C Previsão para o período abr/08-mar/09 (R\$ bilhões)

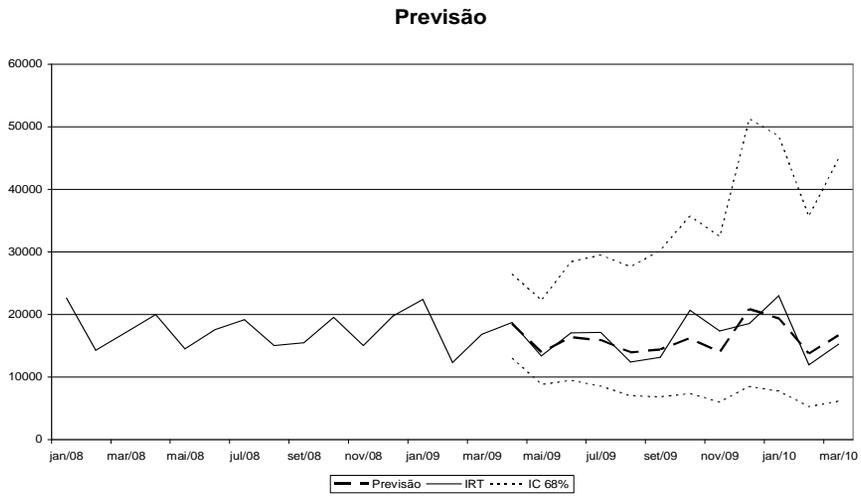


Figura C.1: Imposto de renda — total

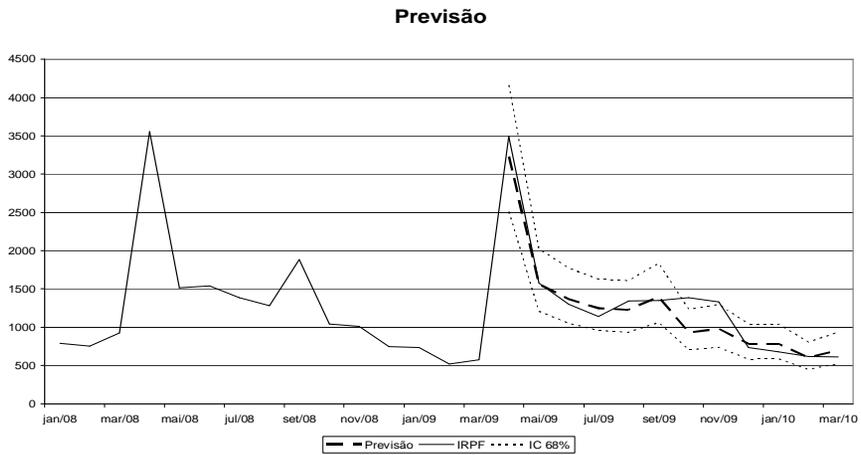


Figura C.2: Imposto de renda — pessoa física

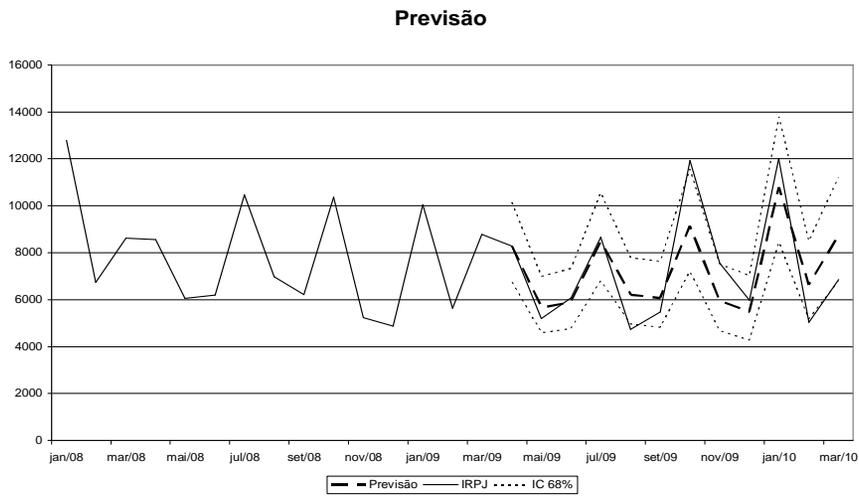


Figura C.3: Imposto de renda — pessoa jurídica — total

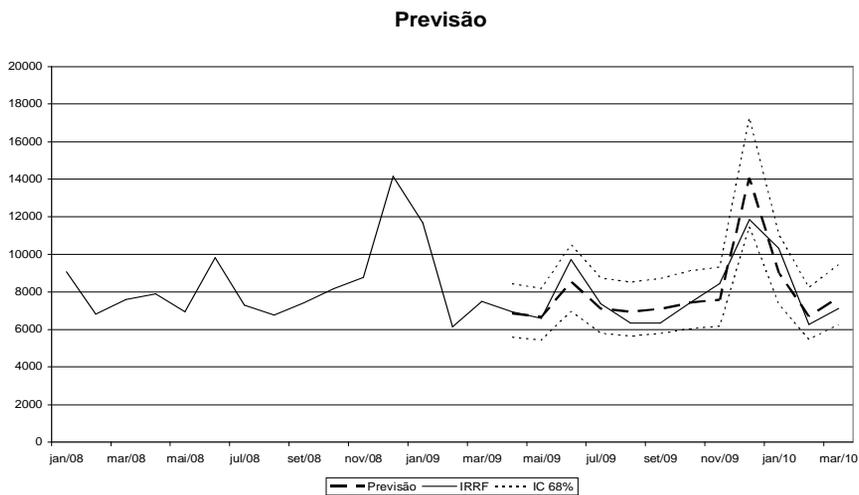


Figura C.4: Imposto de renda — retido na fonte — total

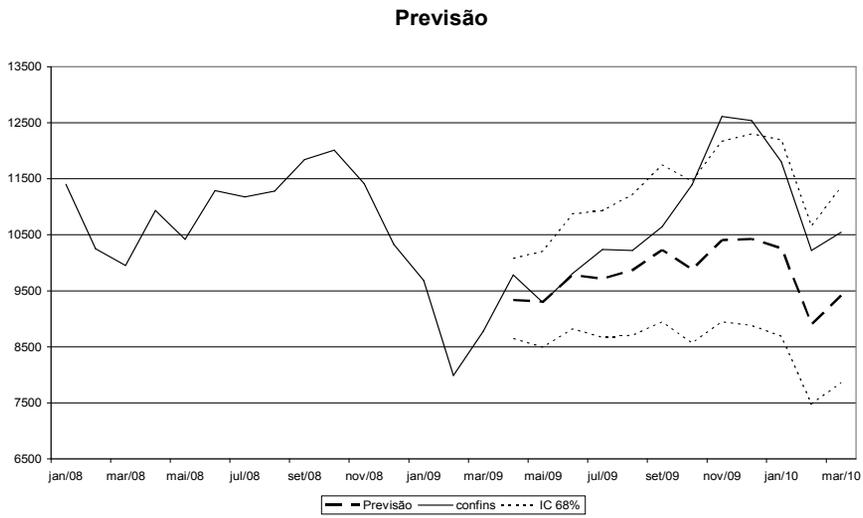


Figura C.5: COFINS

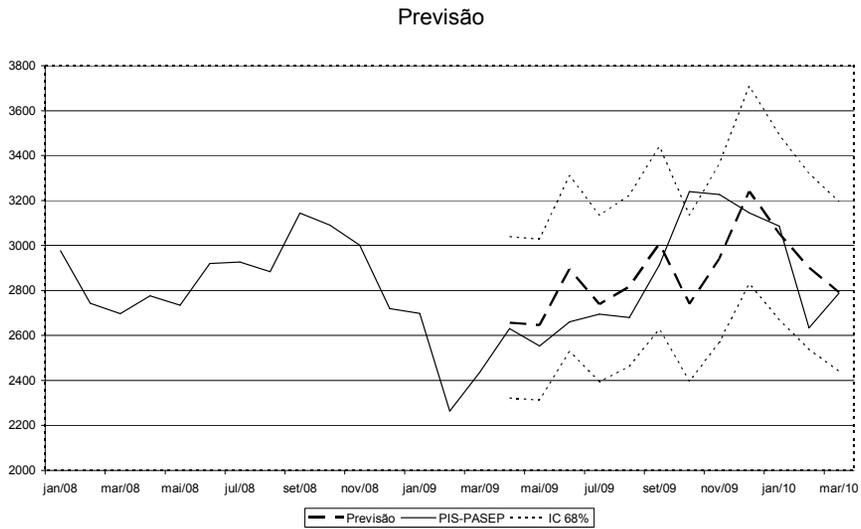


Figura C.6: PIS-PASEP

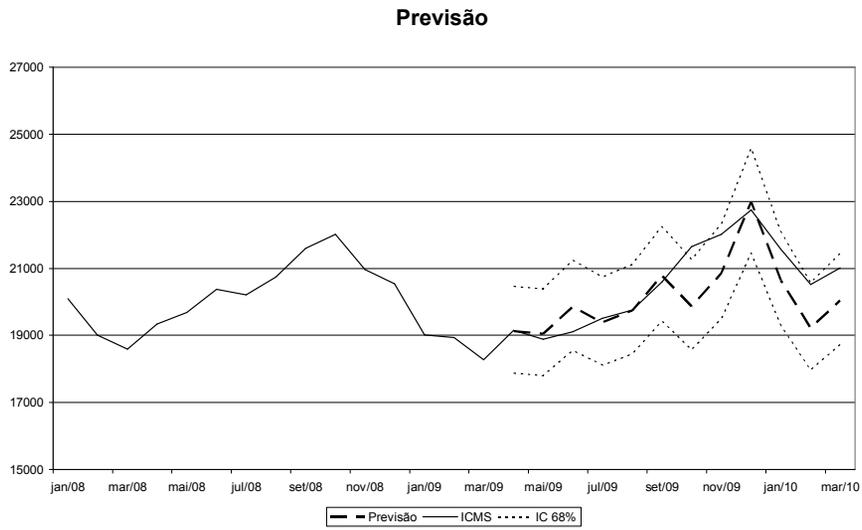


Figura C.7: ICMS

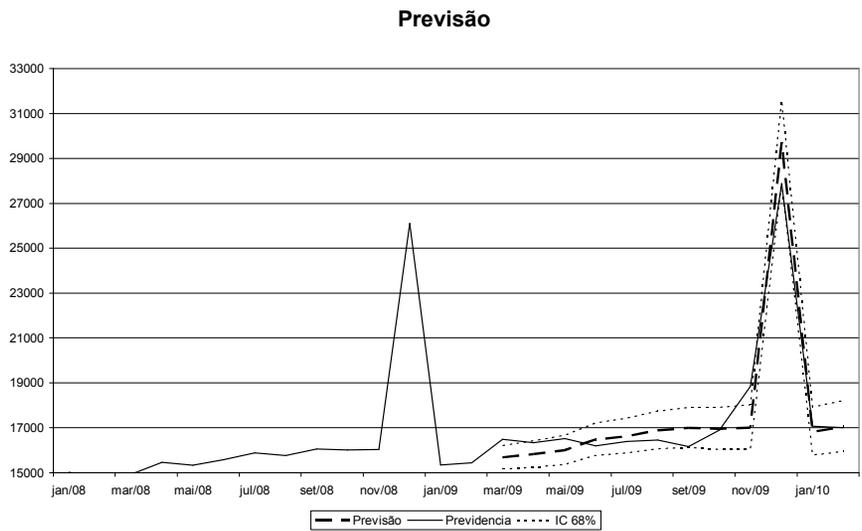


Figura C.8: Previdência

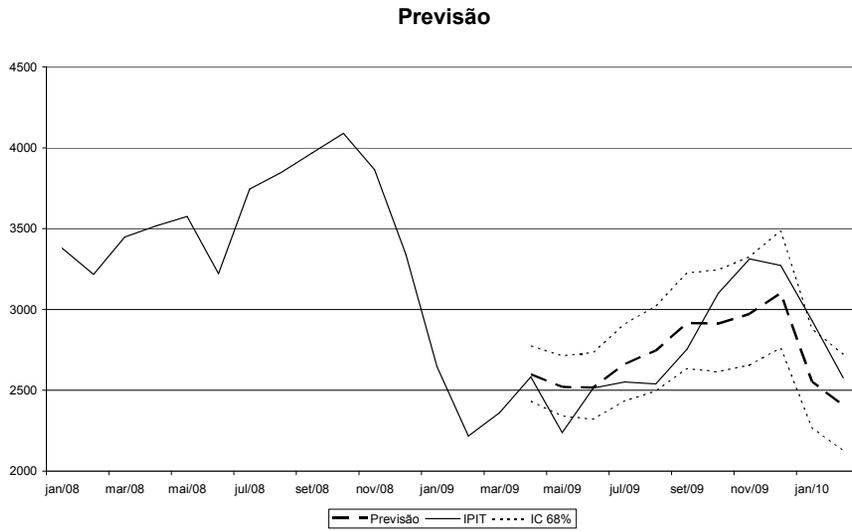


Figura C.9: Imposto sobre Produtos Industrializados — IPI

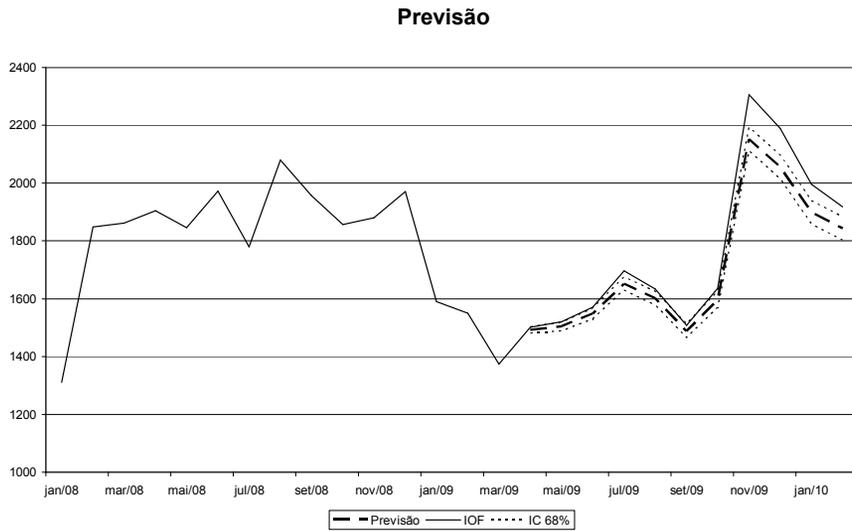


Figura C.10: IOF

Apêndice D Erro de previsão (R\$ milhões)**Tabela D.1: IRT**

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	18,717	18,550	13,012	26,444	168	0,9
Mai./09	13,363	13,997	8,817	22,222	-634	-4,75
Jun./09	17,105	16,404	9,464	28,435	700	4,09
Jul./09	17,176	15,885	8,552	29,507	1,290	7,51
Ago./09	12,418	13,943	7,039	27,619	-1,525	-12,28
Set./09	13,173	14,417	6,882	30,204	-1,244	-9,44
Out./09	20,733	16,216	7,365	35,704	4,517	21,79
Nov./09	17,331	13,993	6,036	32,439	3,338	19,26
Dez./09	18,566	20,908	8,525	51,278	-2,343	-12,62
Jan./10	23,024	19,368	7,743	48,444	3,656	15,88
Fev./10	11,931	13,744	5,296	35,667	-1,813	-15,2
Mar./10	15,291	16,650	6,178	44,867	-1,358	-8,88

Fonte: Elaboração dos autores.

Tabela D.2: IRPF

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	3,489	3,230	2,509	4,158	260	7,45
Mai./09	1,579	1,565	1,211	2,023	14	0,88
Jun./09	1,301	1,365	1,051	1,774	-64	-4,96
Jul./09	1,143	1,247	956	1,628	-104	-9,09
Ago./09	1,343	1,228	936	1,610	115	8,58
Set./09	1,350	1,395	1,061	1,835	-45	-3,35
Out./09	1,389	933	704	1,235	456	32,84
Nov./09	1,331	981	741	1,299	350	26,29
Dez./09	738	782	585	1,046	-44	-5,98
Jan./10	680	786	590	1,046	-105	-15,5
Fev./10	619	605	454	807	14	2,23
Mar./10	613	702	525	938	-88	-14,41

Fonte: Elaboração dos autores.

Tabela D.3: IRPJ — Total

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	8,289	8,273	6,744	10,149	16	0,19
Mai./09	5,186	5,666	4,594	6,987	-480	-9,25
Jun./09	6,074	5,910	4,765	7,329	164	2,7
Jul./09	8,660	8,474	6,800	10,559	186	2,15
Ago./09	4,741	6,213	4,959	7,784	-1,472	-31,05
Set./09	5,468	6,069	4,826	7,633	-602	-11
Out./09	11,931	9,132	7,215	11,558	2,799	23,46
Nov./09	7,567	5,932	4,677	7,522	1,636	21,62
Dez./09	5,970	5,483	4,282	7,022	487	8,16
Jan./10	12,018	10,790	8,445	13,787	1,228	10,22
Fev./10	5,035	6,629	5,173	8,496	-1,594	-31,66
Mar./10	6,855	8,726	6,791	11,211	-1,871	-27,29

Fonte: Elaboração dos autores.

Tabela D.4: IRRF — total

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	6,939	6,866	5,593	8,428	73	1,05
Mai./09	6,598	6,669	5,432	8,188	-71	-1,08
Jun./09	9,730	8,555	6,968	10,503	1,175	12,08
Jul./09	7,372	7,113	5,794	8,733	259	3,51
Ago./09	6,335	6,937	5,649	8,518	-602	-9,5
Set./09	6,355	7,098	5,781	8,715	-743	-11,69
Out./09	7,413	7,425	6,047	9,117	-12	-0,16
Nov./09	8,433	7,592	6,183	9,321	841	9,97
Dez./09	11,857	14,075	11,464	17,282	-2,218	-18,71
Jan./10	10,325	9,004	7,333	11,056	1,321	12,79
Fev./10	6,277	6,704	5,461	8,230	-427	-6,81
Mar./10	7,120	7,686	6,260	9,436	-566	-7,95

Fonte: Elaboração dos autores.

Tabela D.5: Cofins

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	9,784	9,332	8,648	10,077	452	4,62
Mai./09	9,291	9,304	8,496	10,205	-13	-0,14
Jun./09	9,812	9,784	8,819	10,874	28	0,29
Jul./09	10,239	9,719	8,664	10,929	519	5,07
Ago./09	10,224	9,864	8,706	11,215	360	3,52
Set./09	10,644	10,229	8,941	11,746	415	3,89
Out./09	11,397	9,881	8,566	11,456	1,516	13,3
Nov./09	12,611	10,408	8,946	12,169	2,203	17,47
Dez./09	12,542	10,428	8,880	12,300	2,114	16,85
Jan./10	11,803	10,261	8,686	12,193	1,542	13,06
Fev./10	10,223	8,901	7,479	10,654	1,322	12,94
Mar./10	10,545	9,418	7,857	11,352	1,128	10,7

Fonte: Elaboração dos autores.

Tabela D.6: PIS/PASEP

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	2,630	2,656	2,321	3,039	-26	-0,97
Mai./09	2,553	2,647	2,313	3,028	-93	-3,66
Jun./09	2,661	2,894	2,529	3,312	-233	-8,77
Jul./09	2,694	2,738	2,393	3,133	-45	-1,66
Ago./09	2,680	2,817	2,462	3,223	-137	-5,11
Set./09	2,913	3,007	2,627	3,441	-94	-3,23
Out./09	3,240	2,740	2,395	3,134	500	15,43
Nov./09	3,227	2,940	2,569	3,364	287	8,89
Dez./09	3,145	3,240	2,829	3,709	-94	-3
Jan./10	3,087	3,054	2,669	3,493	33	1,07
Fev./10	2,634	2,902	2,536	3,320	-268	-10,18
Mar./10	2,788	2,792	2,440	3,195	-3	-0,12

Fonte: Elaboração dos autores.

Tabela D.7: ICMS

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	19,155	19,126	17,873	20,466	30	0,16
Mai./09	18,884	19,047	17,799	20,382	-163	-0,86
Jun./09	19,109	19,846	18,545	21,239	-738	-3,86
Jul./09	19,510	19,382	18,112	20,741	128	0,65
Ago./09	19,758	19,737	18,443	21,121	21	0,11
Set./09	20,597	20,784	19,420	22,243	-187	-0,91
Out./09	21,651	19,865	18,565	21,256	1,785	8,25
Nov./09	22,022	20,858	19,490	22,321	1,165	5,29
Dez./09	22,741	22,972	21,460	24,590	-231	-1,01
Jan./10	21,574	20,648	19,297	22,093	927	4,3

Fonte: Elaboração dos autores.

Tabela D.8: Previdência

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	16,481	15,676	15,157	16,212	790	4,79
Mai./09	16,333	15,820	15,242	16,420	527	3,22
Jun./09	16,527	16,002	15,366	16,663	563	3,4
Jul./09	16,189	16,480	15,777	17,216	-256	-1,58
Ago./09	16,389	16,630	15,873	17,423	-174	-1,06
Set./09	16,450	16,883	16,068	17,739	-355	-2,16
Out./09	16,167	16,994	16,127	17,907	-753	-4,66
Nov./09	16,896	16,949	16,039	17,911	87	0,51
Dez./09	18,839	17,009	16,051	18,024	1,942	10,31
Jan./10	27,858	29,710	27,939	31,593	-1,768	-6,34
Fev./10	17,070	16,824	15,789	17,926	404	2,36
Mar./10	17,000	17,043	15,949	18,211	111	0,65

Fonte: Elaboração dos autores.

Tabela D.9: IPI

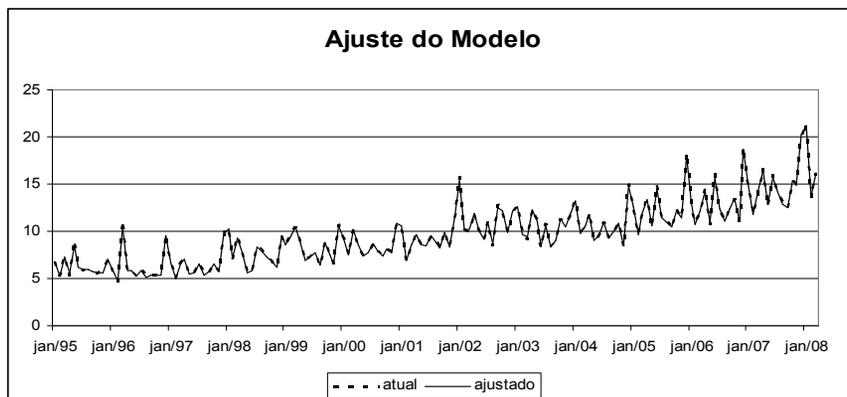
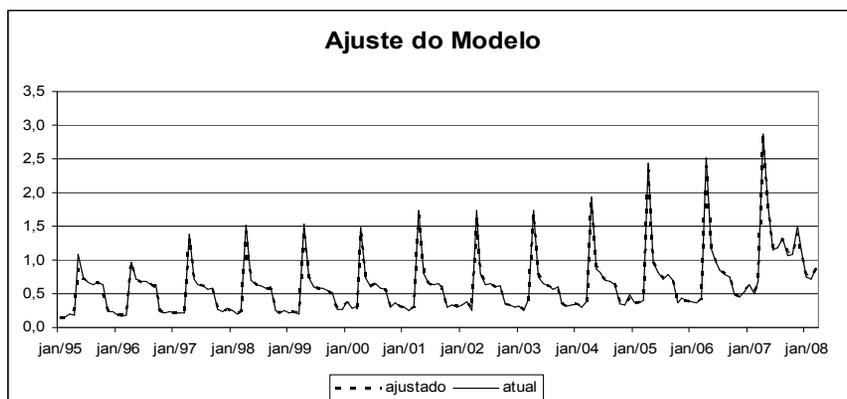
	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	2,582	2,597	2,432	2,773	19	0,73
Mai./09	2,238	2,520	2,340	2,714	-241	-10,76
Jun./09	2,513	2,518	2,320	2,732	57	2,25
Jul./09	2,551	2,660	2,434	2,908	-20	-0,77
Ago./09	2,539	2,745	2,495	3,020	-127	-5,01
Set./09	2,755	2,915	2,634	3,226	-41	-1,48
Out./09	3,100	2,913	2,615	3,245	297	9,56
Nov./09	3,312	2,972	2,656	3,325	530	16
Dez./09	3,274	3,102	2,760	3,485	208	6,35
Jan./10	2,931	2,554	2,267	2,877	408	13,92
Fev./10	2,577	2,405	2,126	2,721	223	8,65
Mar./10	2,767	2,563	2,249	2,920	300	10,83

Fonte: Elaboração dos autores.

Tabela D.10: IOF

	IRT	Previsão	I.C. 68%		Erro	Erro (%)
Abr./09	1,502	1,492	1,481	1,504	10	1
Mai./09	1,521	1,504	1,489	1,519	17	1
Jun./09	1,571	1,549	1,531	1,568	22	1
Jul./09	1,696	1,652	1,630	1,675	44	3
Ago./09	1,635	1,602	1,578	1,626	33	2
Set./09	1,508	1,489	1,464	1,513	19	1
Out./09	1,636	1,598	1,570	1,626	38	2
Nov./09	2,306	2,152	2,111	2,193	154	7
Dez./09	2,190	2,055	2,014	2,097	134	6
Jan./10	1,996	1,898	1,859	1,939	98	5
Fev./10	1,918	1,843	1,803	1,884	75	4
Mar./10	1,929	1,847	1,805	1,890	81	4

Fonte: Elaboração dos autores.

Apêndice E Ajustamento do modelo**Figura E.1: Imposto de renda — Total****Figura E.2: Imposto de renda — pessoa física**

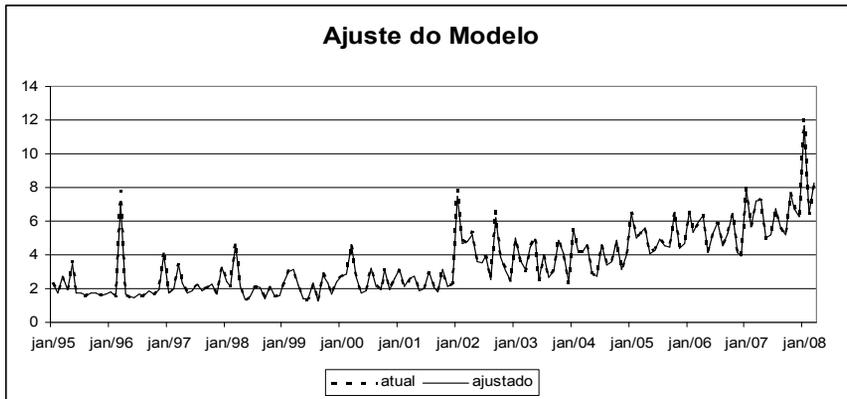


Figura E.3: Imposto de renda — pessoa jurídica — Total

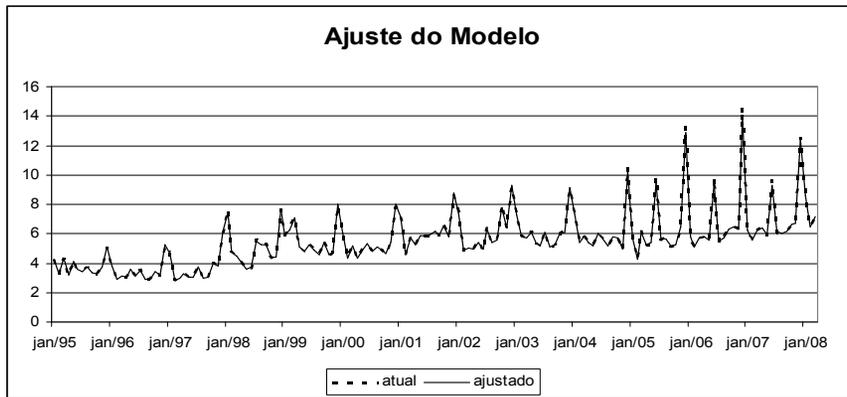


Figura E.4: Imposto de renda — Retido na Fonte — Total

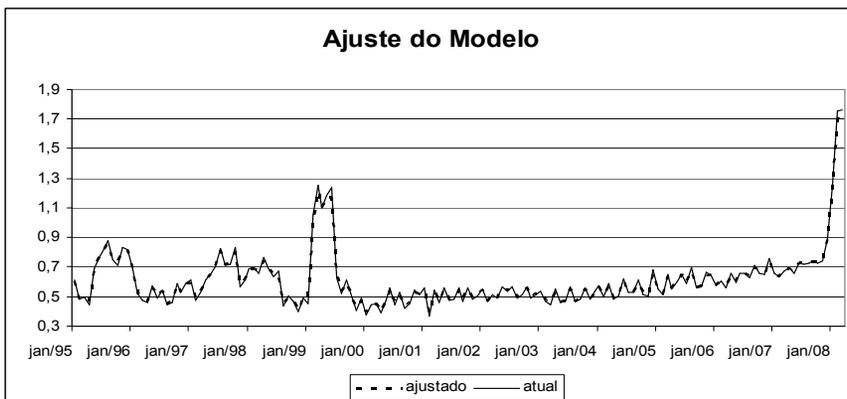
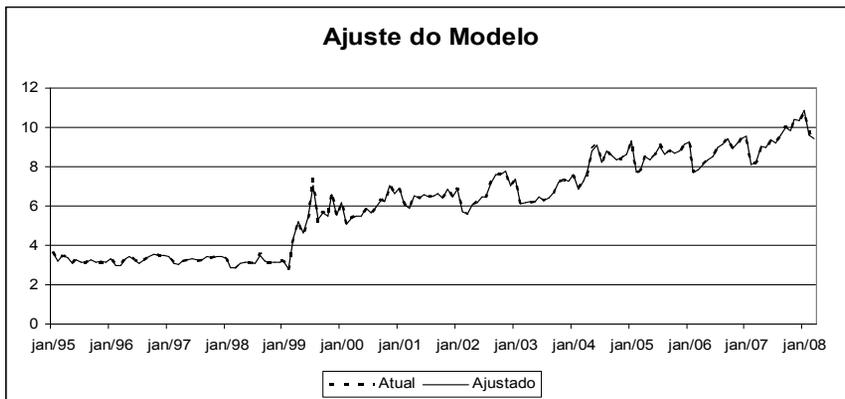
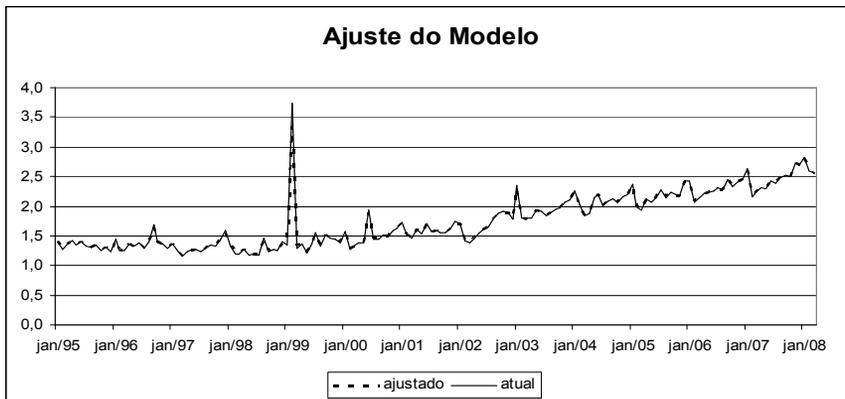
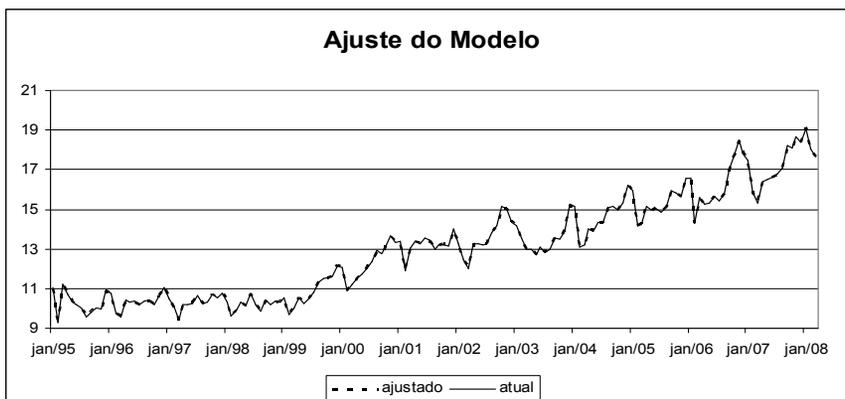


Figura E.5: Imposto sobre Operações Financeiras — IOF

**Figura E.6: COFINS****Figura E.7: PIS-PASEP****Figura E.8: ICMS**

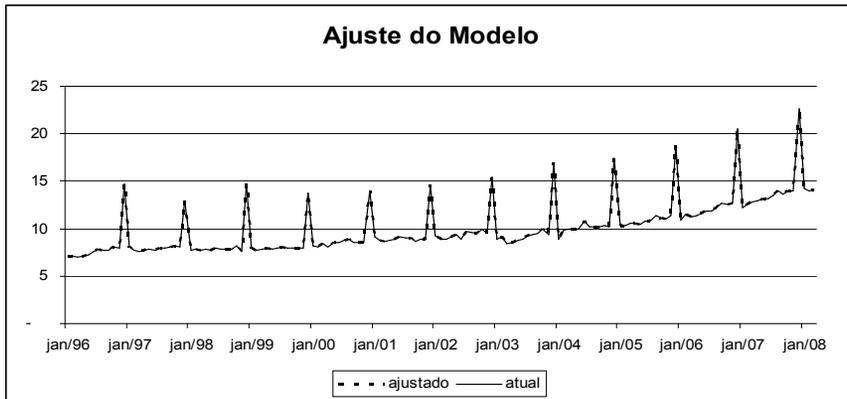


Figura E.9: Previdência

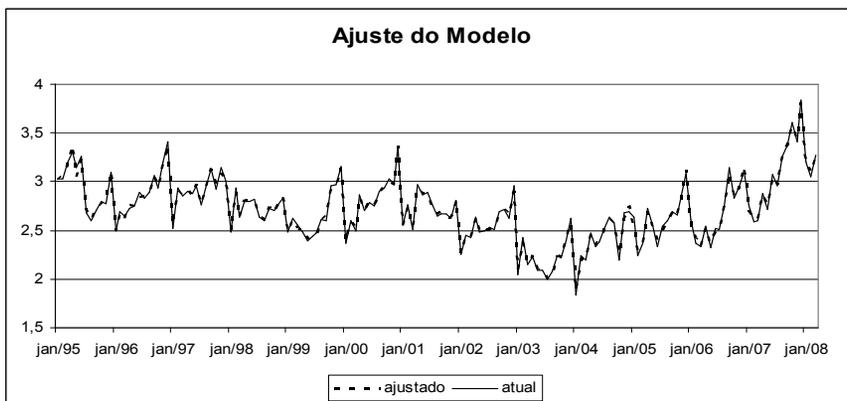


Figura E.10: Imposto sobre Produtos Industrializados — IPI