

FUNDAÇÃO GETÚLIO VARGAS  
ESCOLA DE ECONOMIA DE SÃO PAULO

THIAGO CARLOMAGNO CARLOS

**PROJEÇÃO DE INFLAÇÃO NO BRASIL UTILIZANDO DADOS AGREGADOS E  
DESAGREGADOS: UM TESTE DE PODER PREDITIVO POR HORIZONTE DE  
TEMPO**

SÃO PAULO

2012

THIAGO CARLOMAGNO CARLOS

**PROJEÇÃO DE INFLAÇÃO NO BRASIL UTILIZANDO DADOS AGREGADOS E  
DESAGREGADOS: UM TESTE DE PODER PREDITIVO POR HORIZONTE DE  
TEMPO**

Dissertação apresentada à Escola de Economia  
de São Paulo da Fundação Getúlio Vargas,  
como requisito para obtenção do título de  
Mestre em Economia

Campo de conhecimento: Economia

Orientador: Prof. Dr. Emerson Fernandes  
Marçal

SÃO PAULO

2012

Carlomagno Carlos, Thiago.

Projeção de inflação no Brasil utilizando dados agregados e desagregados: um teste de poder preditivo por horizonte de tempo / Thiago Carlomagno Carlos. - 2012. 53 f.

Orientador: Emerson Fernandes Marçal.

Dissertação (MPFE) - Escola de Economia de São Paulo.

1. Inflação - Brasil. 2. Modelos lineares (Estatística). 3. Índice Nacional de Preços ao Consumidor Amplo. 4. Kalman, Filtragem de. I. Marçal, Emerson Fernandes. II. Dissertação (MPFE) - Escola de Economia de São Paulo. III. Título.

CDU 338.748.12

THIAGO CARLOMAGNO CARLOS

**PROJEÇÃO DE INFLAÇÃO NO BRASIL UTILIZANDO DADOS AGREGADOS E  
DESAGREGADOS: UM TESTE DE PODER PREDITIVO POR HORIZONTE DE  
TEMPO**

Dissertação apresentada à Escola de Economia  
de São Paulo da Fundação Getúlio Vargas,  
como requisito para obtenção do título de  
Mestre em Economia

Campo de conhecimento: Economia

**Data da aprovação:**

\_\_/\_\_/\_\_

**Banca examinadora:**

---

Prof. Dr. Emerson Fernandes Marçal  
(orientador)

FGV - EESP

---

Prof. Dr. Paulo Picchetti

FGV – EESP

---

Prof<sup>a</sup> Dr. Marislei Nishijima

USP - EACH

## AGRADECIMENTOS

Após dois anos e meio de dedicação e empenho, a conclusão do mestrado com este trabalho final não ocorreria sem a ajuda de muitas pessoas. A cada conquista ou objetivos alcançado em nossas vidas, temos de nos lembrar de todas aquelas pessoas que nos ajudaram a consegui-los. A maioria delas compartilharam nossas angústias, medos, tensões e aguentaram o nosso mau humor ao longo dos períodos de estresse. Assim, tenho que agradecer a minha família que aturou todas as minhas oscilações de humor que variavam entre mal-humorado e muito mal-humorado. A todos os meus colegas de classe (mencionar só alguns seria injusto) com os quais compartilhei listas de exercícios, resumos e aulas em um sábado à tarde ensolarado. E a todos os professores e funcionário da EESP que tornaram estes anos em um grande aprendizado. Mas aos professores é necessário um agradecimento adicional, porque corrigir uma prova escrita com a minha letra não deve ser uma das tarefas mais fáceis. Obrigado pela paciência.

Obviamente, alguns agradecimentos especiais também devem ser feitos. Agradeço ao meu orientador, não só pela ideia de tema, como também pelo apoio e suporte durante o trabalho. Agradeço também algumas pessoas que me ajudaram no trabalho, como uma macro especial criada pelo meu amigo Lucas Namó Cury, e pelos conselhos, explicações de econometria, conversas e ajuda nos softwares de meu amigo e mentor, Fabio Maciel Ramos.

Agradeço a Link Investimentos, empresa em que trabalho, que custeou parte dos meus estudos e investiu em minha formação. Sem o suporte da empresa, a confiança depositada em mim pelo Marcelo Okura e Daniel, que souberam ser compreensivo nos momentos mais difíceis ao longo desta jornada, também não teria conseguido esta conquista. Também devo agradecer a Marianna Costa, que foi a primeira a me ver como um economista em potencial, e me ensinou a ser um melhor economista ao longo destes anos.

Enfim, não dá para mencionar todas as pessoas, pois todas as pessoas que passam pelas nossas vidas nos influenciam de alguma forma. Mas, a dedicatória deste trabalho vai para uma pessoa esteve sempre presente em todas as fases da minha vida.

*À minha mãe*

## RESUMO

O trabalho tem como objetivo comparar a eficácia das diferentes metodologias de projeção de inflação aplicadas ao Brasil. Serão comparados modelos de projeção que utilizam os dados agregados e desagregados do IPCA em um horizonte de até doze meses à frente. Foi utilizado o IPCA na base mensal, com início em janeiro de 1996 e fim em março de 2012. A análise fora da amostra foi feita para o período entre janeiro de 2008 e março de 2012. Os modelos desagregados serão estimados por SARIMA, pelo software X-12 ARIMA disponibilizado pelo *US Census Bureau*, e terão as aberturas do IPCA de grupos (9) e itens (52), assim como aberturas com sentido mais econômico utilizadas pelo Banco Central do Brasil como: serviços, administrados, alimentos e industrializados; duráveis, não duráveis, semiduráveis, serviços e administrados. Os modelos agregados serão estimados por técnicas como SARIMA, modelos estruturais em espaço-estado (Filtro de Kalman) e *Markov-switching*. Os modelos serão comparados pela técnica de seleção de modelo *Model Confidence Set*, introduzida por Hansen, Lunde e Nason (2010), e Diebold e Mariano (1995), no qual encontramos evidências de ganhos de desempenho nas projeções dos modelos mais desagregados em relação aos modelos agregados.

**Palavras-chave:** Inflação, projeção, modelos lineares, modelos não lineares, ARIMA, espaço-estado, Filtro de Kalman, *Markov-switching*, *Model Confidence Set*

## ABSTRACT

This work has aim to compare the forecast efficiency of different types of methodologies applied to Brazilian consumer inflation. We will compare forecasting models using disaggregated and aggregated data from IPCA over twelve months ahead. We used IPCA in a monthly basis, over the period between January 1996 to March 2012. Out-of-sample analysis will be made through the period of January 2008 to March 2012. The disaggregated models were estimated by SARIMA using X-12 ARIMA software provided by US Census Bureau, and will have different levels of disaggregation from IPCA as groups (9) and items (52), as well as disaggregation with more economic sense used by Brazilian Central Bank as: services, monitored prices, food and industrials; durables, non-durables, semi durables, services and monitored prices. Aggregated models will be estimated by time series techniques as SARIMA, space-estate structural models (Kalman Filter) and Markov-switching. The forecasting accuracy among models will be made by the selection model procedure known as Model Confidence Set, introduced by Hansen, Lunde and Nason (2010), and by Dielbod Mariano (1995), in which we founded evidences of gain in accuracy in models with more disaggregation than aggregates models.

**Keywords:** Inflation, forecasting, linear models, non-linear models, ARIMA, space-state, Kalman Filter, Markov-switching, Model Confidence Set



## Lista de Figuras

Figura 4.1 – Erro quadrático médio de projeção dos modelos estimados por horizonte de projeção .....	32
--	----

## Lista de Tabelas

Tabela 3.1 – ModelConfidence Set: p-valor.....	20
Tabela 3.2 – Pesos Grupos IPCA nas alterações da POF .....	28
Tabela 3.3 – Pesos IPCA das Classificações do BCB nas alterações da POF .....	29
Tabela 3.4 – Modelos estimados e suas desagregações.....	30
Tabela 4.1 – Erro Quadrático Médio dos modelos por horizonte de projeção.....	32
Tabela 4.2 – Model Confidence Set e p-valor dos modelos estimados.....	34
Tabela 4.3 – Diebold-Mariano teste do modelo mais desagregado em relação dos demais, por horizonte de tempo .....	36

## SUMÁRIO

1	Introdução e motivação .....	10
2	Revisão bibliográfica.....	12
2.1	Metodologias de projeção .....	12
2.2	Comparação do poder preditivo dos modelos.....	15
3	Metodologia e tratamentos dos dados .....	17
3.1	Metodologia de comparação de modelos – Model Confidence Set.....	17
3.1.1	<i>Apresentação do MCS</i> .....	18
3.1.2	<i>Como interpretar o p-valor do MCS</i> .....	20
3.1.3	<i>Testes de equivalência e regras de eliminação</i> .....	21
3.2	Modelos SARIMA (Modelo autorregressivo integrado de média móvel com sazonalidade) .....	22
3.3	Modelo Estrutural para séries de tempo.....	23
3.4	Modelo Markov Switching .....	25
3.5	Tratamento dos dados .....	26
4	Resultados .....	31
4.1	Resultados do MCS .....	33
4.2	Comparação MCS com o teste de Diebold & Mariano (1995).....	34
5	Possíveis extensões e limitações do trabalho .....	37
6	Conclusão .....	38
	Anexos.....	39
	Referências Bibliográficas.....	50

## 1 INTRODUÇÃO E MOTIVAÇÃO

Exercícios de projeção de inflação têm um papel importante dentro dos trabalhos empíricos de macroeconometria. No caso brasileiro, o período de forte aumento da inflação na década de 80 e primeira metade dos anos 90 levou a adoção de diversos planos de estabilização, criando-se a consciência das vantagens da estabilidade de preço. A inflação medida pelo Índice Geral de Preços – Disponibilidade Interna (IGP-DI) da Fundação Getúlio Vargas (FGV) chegou a alcançar incríveis 2.708,17% no ano de 1993 (Gráfico 1). O problema de inflação crônica só foi solucionado com o Plano Real, lançado no final de 1993, resultando na substituição da moeda antiga pelo Real a partir de julho de 1994.

A estabilização econômica recente em termos históricos também cria problemas para análise de dinâmica da inflação brasileira devido a uma série histórica relativamente curta, problema comum nos países em desenvolvimento. Tantos os problemas de disponibilidade de dados como a abundância de transformações institucionais torna-se difícil projetar o futuro através das informações passadas, como Schwartzman (2006) observa. Um segundo passo importante da estabilização econômica veio da adoção do regime de metas de inflação em junho de 1999, no qual o Banco Central é o responsável por buscar a estabilidade de preços e garantir que a inflação efetiva esteja em linha com a meta pré-estabelecida. A adoção do regime de metas ocorreu em um momento importante, no qual surgiu o tripé de política econômica com a adoção do câmbio flutuante (em janeiro de 1999) e a geração consistente de superávits primários com a estabilização da relação dívida/PIB.

A adoção do regime de metas se torna um diferencial fundamental no desenvolvimento dos modelos econométricos de inflação no Brasil. Segundo Chauvet (2000), para tornar o regime de metas de inflação operacional, a comparação das projeções de inflação em relação à meta anunciada se torna uma ferramenta no processo de decisão de política monetária. Uma política de controle da inflação depende da habilidade de se estimar o passo da inflação, tendências e ciclos. Dado a defasagem dos mecanismos de transmissão da política monetária na economia, as projeções de inflação tornam-se uma ferramenta de grande importância dentro do processo de decisão de um banqueiro central.

A projeção de inflação não é importante apenas para autoridade monetária, como também é de grande importância para os agentes privados, que tentam entender e reagem ao

comportamento do banco central. Uma projeção de inflação mais precisa também é de grande utilidade na política fiscal, negociações salariais e também nos mercados financeiros.

Neste contexto, é crucial obter projeções de inflação cada vez mais precisas em diversos horizontes. Em busca das melhores técnicas de projeções, diversas abordagens foram estudadas ao longo do tempo. Modelos agregados e desagregados, com linearidade e não-linearidade, modelos estruturais de séries de tempo e com curva de Phillips, estão entre algumas das técnicas estudadas.

Neste trabalho busca-se encontrar qual seria a melhor técnica de estimação da inflação dentre os modelos de séries de tempo univariados. Utiliza-se modelos lineares e não-lineares, agregados e desagregados, avaliando o desempenho fora da amostra das projeções para horizontes de 1 a 12 meses à frente utilizando técnicas de comparação de modelos como Diebold e Mariano (1995) e o *Model Confidence Set* de Hansen et al. (2010).

O trabalho está subdividido em mais cinco partes, além desta introdução. Na seção a seguir há uma revisão bibliográfica das metodologias de projeção de inflação e também dos métodos de comparação de modelos. Na terceira seção irá se apresentar uma breve descrição e metodologia dos modelos que serão estimados, além de um detalhamento do *Model Confidence Set*. Também será descrito de que forma os dados foram tratados, suas particularidades e desagregações utilizadas. Na quarta seção serão apresentados os resultados dos modelos estimados e as comparações dos modelos. Na quinta seção serão discutidas as limitações do trabalho e possíveis extensões. E por fim, será apresentada a conclusão.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 METODOLOGIAS DE PROJEÇÃO

Uma das possibilidades que poderiam resultar em projeções mais precisas, envolve desagregação dos dados. Esta alternativa foca na decomposição do índice em diversos subcomponentes, cada um com o seu peso associado, e ao invés de projetar a variável principal são projetados cada um dos subcomponentes individualmente para depois reagregá-los. Nesta abordagem, a desagregação dos dados pode contribuir para aumentar a precisão da projeção, na medida em que cada um dos seus subcomponentes pode ser modelado pelas suas características individuais.

Lütkepohl (1984) argumenta que se o processo gerador dos dados é conhecido, é preferível projetar múltiplas séries de tempo desagregadas e agregá-las do que projetar a série agregada diretamente. No entanto, na prática, o processo gerador dos dados é desconhecido, e Lütkepohl apresenta evidências de que dada a variabilidade de especificação do modelo e estimação, pode ser preferível projetar a variável agregada diretamente. A perda de informação devido a séries agregadas também são tratadas por Khon (1982) e Palm e Nijman (1984), Rose (1977), e Tiao e Guttman (1980). Se a agregação das projeções de fato melhora a precisão das projeções, não é claro, pois depende também do nível de desagregação das séries. Segundo Hendry e Hubrich (2006), o potencial erro de especificação no modelo de projeção das variáveis desagregadas devido à seleção dos modelos, incertezas na estimação, assim como erros de medida e quebras estruturais afetam o resultado da projeção. Isso explica o porquê dos resultados teóricos esperados de projeção não serem confirmados nos estudos empíricos. Por exemplo, Hubrich (2005) indica que a agregação das projeções dos componentes da inflação não necessariamente ajuda na projeção da Zona do Euro doze meses à frente. Duarte & Rua (2007) encontram uma relação indireta entre horizonte de projeção e quantidade de informação, ou seja, modelos mais desagregados se mostram mais eficientes nas projeções de curto prazo, enquanto modelos agregados são mais eficientes pra horizontes mais longos.

A agregação das projeções dos componentes da inflação tem recebido bastante atenção do Banco Central Europeu (ver Benalal, Diaz del Hoyo, Landau, Roma e Skudelny

(2004), Reijer e Vlaar (2006), Bruneau, De Bandt, Flageollet e Michaux (2007), Moser, Rumler e Scharler (2007) e Hendry e Hubrich (2010)). Assim como o Federal Reserve Board também utiliza as categorias desagregadas da inflação nas projeções, especialmente no curto prazo (eg. Bernanke (2007)).

Outra forma de se incorporar estruturas mais ricas para modelar séries econômicas consiste na utilização de modelos de projeção da série agregada com estrutura não-lineares. As séries econômicas, em geral, estão sujeitas as alterações de políticas econômicas, na quais podem sofrer alterações de regime. As possíveis mudanças estruturais nas séries econômicas motivaram o desenvolvimento de modelos que incorporassem esta característica particular. Muitos modelos de séries de tempo não lineares foram propostos na literatura, como o modelo bilinear de Granger e Anderson (1978), o modelo autorregressivo com threshold (TAR) de Tong (1978), modelo de espaço-estado, usado na engenharia para representar uma variedade de processo físicos, e sua introdução e comparação de aplicações em econometria e engenharia foi realizado por Mehra (1974) e o modelo *Markov-switching* proposto por Hamilton (1989).

Iremos focar em dois modelos não lineares utilizados no trabalho e suas aplicações que são os modelos *Markov-switching* e o de espaço-estado (Filtro de Kalman). Um grande número de estudos de não linearidade na inflação busca investigar a hipótese de Friedman de que altas taxas de inflação levam a uma maior variância da inflação futura. Friedman sugere que a incerteza em relação ao regime de inflação possa ser a fonte fundamental da relação positiva entre taxa de inflação e volatilidade. Os modelos *Markov-switching* foram desenhados especialmente para capturar este tipo de fenômeno nas séries. Evans e Wachtel (1993) apresenta um modelo *Markov-switching* para a série de inflação norte-americana com dois regimes, um processo AR(1) e um passeio aleatório com *drift*, mostrando que no período de 35 anos houve diversas alterações de regime de inflação com impactos importantes sobre as projeções dos agentes racionais, e sobre a incerteza associada a inflação futura. Kim (1993) estende o modelo de componentes não observados em espaço-estado, incluindo heterocedasticidade com mudança markoviana de regime para a inflação dos EUA. Em busca dos melhores modelos univariados para a inflação americana, Bidarkota e Mcculloch (1998) utilizam um modelo univariado de espaço-estado com erros simetricamente distribuídos. Os autores apontam as diferenças na adaptação à série de inflação a choques, persistentes ou transitórios, mudança de nível entre os modelos não Gaussianos (filtrados pelo algoritmo de Sorenson e Alspach (1971)) e Gaussianos (Filtro de Kalman) de espaço-estado.

O modelo não Gaussiano encontra *outliers* e mudanças de nível melhor e provê melhores estimativas da tendência da inflação e gera avaliações mais realistas nos períodos mais turbulentos. Bidarkota (2001) compara as projeções de inflação dos Estados Unidos utilizando modelos espaço-estado e de mudança markoviana de regime, no qual os modelos apresentam resultados bastante semelhantes, muito embora, os modelos em espaço-estado sejam considerados mais parcimoniosos e tenham superado o modelo *Markov-switching* nos critérios de informação AIC e SBC.

Uma segunda linha que explora formas de aumentar a precisão das projeções considera a possibilidade de condensar uma ampla variedade de séries econômicas em um pequeno número de variáveis que retém as principais características dos dados originais. Esta abordagem não foi utilizada no trabalho, mas é uma das possibilidades de extensão bastante interessante ao estudo. Stock e Watson (1998) usando uma aproximação de um modelo dinâmico fatorial utilizam um grande número de previsores, condensando-os em poucos índices semelhantes aos índices de difusão, que são médias ponderadas dos previsores. Esta técnica é aplicada para a projeção da inflação e produção industrial americanas, utilizando 224 séries mensais, resultando em projeções melhores em relação a vários modelos base. Bernanke, Boivin e Elias (2005) e Stock e Watson (2002) exploram o uso dos índices de difusão em modelos de vetores autoregressivos (FAVAR) e suas aplicações na política monetária. Duarte e Rua (2007) incorporam os modelos dinâmicos fatoriais na estrutura SARIMA para a projeção de inflação, chamando-os de FASARIMA (Factor-Augmented SARIMA). Castle, Hendry e Clements (2011) comparam modelos fatoriais com modelos estimados por variáveis utilizando o algoritmo Autometrics<sup>1</sup> no OxMetrics para a projeção de inflação e PIB dos Estados Unidos. Os resultados sugerem que os modelos fatoriais na projeção um passo a frente, enquanto a seleção de variáveis pelo Autometrics resulta em menor erro de projeção para horizontes mais longos.

No caso brasileiro, a maioria das alternativas de modelos de projeção de inflação utilizam a curva de Phillips. Bogdanski et al (2000) apresenta um modelo estrutural de pequeno porte para representar os canais de transmissão de política monetária, estimando uma curva de Phillips como parte do modelo. Na tentativa de construção de um indicador antecedente para a inflação brasileira, Chauvet (2000) cria um modelo de fatores dinâmicos utilizando Filtro de Kalman. Entre as tentativas de estimar a curva de Phillips para o Brasil, Schuartzman (2006) estima uma curva de Phillips desagregada, fazendo uso do método de

---

<sup>1</sup> Ver manual do PcGive do Doornik, J. A. e Hendry (2007)

mínimos quadrados em três estágios, utilizando dados trimestrais para amostras diferentes. Areosa e Medeiros (2007), derivam um modelo estrutural para inflação em uma economia aberta, utilizando uma representação da curva de Phillips novo-keynesiana padrão e uma curva híbrida. Sachsida et al. (2009) estima uma curva de Phillips com dados trimestrais, no qual foi adotado um modelo *Markov-switching* de mudança de regime, observando que os coeficientes estimados são altamente sensíveis, sugerindo uma inadequação da curva de Phillips em explicar a dinâmica inflacionária na economia brasileira. Arruda, Ferreira e Castelar (2011), compara previsões da inflação brasileira, com dados mensais, utilizando modelos lineares e não lineares de séries temporais e de curva de Phillips. As comparações foram realizadas utilizando o teste proposto por Diebold e Mariano (1995), mostrando que o modelo de curva de Phillips ampliada com efeito *threshold* apresenta um ganho de desempenho de projeção em relação aos modelos lineares no período de janeiro de 2006 a dezembro de 2006. Entre todos os estudos averiguados para a inflação brasileira, não é de nosso conhecimento a existência de trabalhos que projetem a inflação para o nível de desagregação que iremos utilizar neste trabalho, em que serão projetados os 52 itens para o período recente.

## 2.2 COMPARAÇÃO DO PODER PREDITIVO DOS MODELOS

Diversos trabalhos dentro da literatura estudaram o problema de seleção do melhor modelo de projeção dentre um conjunto de modelos. É de amplo conhecimento que o aumento no número de variáveis em uma regressão melhora a aderência do modelo dentro da amostra, reduzindo, por exemplo, o erro quadrático médio, mas as piores projeções acabam sendo dos modelos com maior número de variáveis.

Engle e Brown (1985) comparam os procedimentos de seleção de modelos baseados em seis critérios de informação com dois procedimentos de teste, mostrando que os critérios que penalizam de forma mais pesada a superparametrização dos modelos apresentaram os melhores desempenhos. Inoue e Kilian (2006) compararam os procedimentos de seleção baseados em os critérios de informação e a avaliação fora da amostra pelo erro quadrático médio de projeção.



Um problema semelhante, conhecido como *multi comparison with control*, é o caso quando todos os objetos são comparados com um *benchmark*, ou seja, é escolhido um modelo base, no qual seu desempenho é comparado com todos os demais modelos. Nesta linha, um teste de equivalência de previsão foi proposto por Diebold e Mariano (1995), no qual propõe um teste formal entre dois modelos de previsão competidores sob a hipótese nula de equivalência de precisão. Harvey, Leybourne, e Newbold (1997) sugerem uma modificação para o teste de Diebold e Mariano para tratar melhor casos de amostra pequena. Ao invés de testar a equivalência de precisão das projeções, White (2000) propõe um procedimento para testar a superioridade da capacidade preditiva (SPA) dos modelos. Enquanto no teste de equivalência se tem uma única hipótese nula a ser testada, o SPA apresenta múltiplas hipóteses de teste. Hansen (2005) apresenta um novo teste SPA, seguindo a construção de White (2000), mas com uma estatística de teste diferente com uma distribuição dependente da amostra para o teste da hipótese nula.

Por fim, Hansen, Lunde e Nason (2010) introduzem o *Model Confidence Set (MCS)* que é um procedimento de comparação de múltiplos modelos, sem a necessidade de se definir um modelo *benchmark*. O MCS é uma metodologia que determina o “melhor” modelo ou conjunto de “melhores” modelos dentro de um intervalo de confiança e tem diversas vantagens em relação às metodologias anteriormente propostas. Faremos uma discussão mais ampla do MCS na próxima seção.

### 3 METODOLOGIA E TRATAMENTOS DOS DADOS

#### 3.1 METODOLOGIA DE COMPARAÇÃO DE MODELOS – MODEL CONFIDENCE SET

O *Model Confidence Set* (MCS) é uma metodologia de comparação de projeções de um conjunto de modelos, determinando o “melhor” modelo ou conjunto de “melhores” modelos dentro de um intervalo de confiança. A metodologia que seguiremos foi introduzida por Hansen et al. (2010).

Segundo Hansen, uma característica atrativa do MCS é que ele reconhece as limitações dos dados, avaliando as informações da amostra sobre o desempenho relativo da coleção de modelos em análise. Se a amostra for bastante informativa, o MCS irá resultar em um único “melhor” modelo. Com uma amostra com dados menos informativos, fica difícil distinguir os modelos, podendo resultar em um MCS que contenha diversos, ou até mesmo todos os modelos. Esta característica difere dos métodos de seleção existentes que escolhem um único modelo sem considerar as informações existentes nos dados.

Outra característica vantajosa do MCS é que é possível fazer comentários sobre a significância que é válida no modo tradicional, propriedade que não é satisfeita na abordagem normalmente utilizada de reportar o *p-valor* de uma comparação múltipla de pares de modelos. Assim, a vantagem do MCS é que o procedimento permite que mais de um modelo seja considerado o “melhor”, resultando em um conjunto de “melhores” modelos.

A forma como o MCS funciona é relativamente simples. Para uma coleção de modelos que competem entre si,  $\mathcal{M}_0$ , o procedimento determina um conjunto,  $\mathcal{M}^*$ , que consiste no conjunto dos melhores modelos de projeção. O procedimento do MCS é baseado em um teste de equivalência,  $\delta_{\mathcal{M}}$ , e uma regra de eliminação,  $e_{\mathcal{M}}$ . O teste de equivalência,  $\delta_{\mathcal{M}}$ , é aplicado para o conjunto de objetos  $\mathcal{M} = \mathcal{M}_0$ . Se  $\delta_{\mathcal{M}}$  é rejeitado, há evidências de que os modelos em  $\mathcal{M}$  não são igualmente bons, e assim, a regra de eliminação,  $e_{\mathcal{M}}$ , é utilizada para eliminar o objeto com o pior desempenho em  $\mathcal{M}$ . Este procedimento é repetido de forma sequencial até que  $\delta_{\mathcal{M}}$  seja aceito, e o MCS será definido como o conjunto de modelos “sobreviventes”. O mesmo nível de significância é aplicado em todos os testes, o que garante

assintoticamente, para um nível de significância  $\alpha$ ,  $P(\mathcal{M}^* \subset \widehat{\mathcal{M}}_{1-\alpha}^*) \geq 1 - \alpha$ , e no caso onde  $\mathcal{M}^*$  consiste de apenas um objeto, tem-se o forte resultado de que  $\lim_{n \rightarrow \infty} P(\mathcal{M}^* \subset \widehat{\mathcal{M}}_{1-\alpha}^*) = 1$ , ou seja, um único objeto “sobrevive” a todos testes quando o  $n$  tende ao infinito e nunca é eliminado, logo sua probabilidade é igual a 1. O MCS também determina um  $p$ -valor para cada um dos modelos (MCS  $p$ -value), que segue uma forma intuitiva e relacionada ao  $p$ -valor dos testes individuais de equivalência entre os modelos, que será melhor discutida posteriormente. De forma resumida, para um dado modelo  $i \in \mathcal{M}_0$ , o  $p$ -valor do MCS,  $\hat{p}_i$ , está na fronteira em que  $i \in \widehat{\mathcal{M}}_{1-\alpha}^*$ , se e somente se,  $p_i \geq \alpha$ . Desta maneira, um modelo com baixo  $p$ -valor dificilmente será um dos modelos selecionados entre o conjunto de melhores modelos  $\mathcal{M}^*$ , enquanto um modelo com alto  $p$ -valor provavelmente fará parte de  $\mathcal{M}^*$ .

Neste sentido, não há necessidade de supor um modelo em particular como sendo o “melhor” modelo, tampouco a hipótese nula de teste é definida por um único modelo. Todos os modelos são tratados de forma igual na comparação e avaliando apenas o seu poder preditivo fora da amostra. Esta é uma das características mais interessantes do MCS.

### 3.1.1 Apresentação do MCS

Nesta seção faremos uma descrição resumida do MCS na comparação de projeção de modelos. Para detalhes adicionais, ver Hansen et al. (2010).

Considere o conjunto  $\mathcal{M}_0$  que contém um número finito de modelos, indexados por  $i = 1, 2, \dots, m_0$ . Estes objetos são avaliados ao longo da amostra  $t = 1, 2, \dots, n$ , por uma função de perda  $L$ . A função de perda associada ao objeto  $i$  no período  $t$  pode ser escrita como  $L_{i,t}$ . Assim, em uma situação em que a projeção  $\hat{Y}_{i,t}$  de  $Y_t$  é avaliada em termos de uma função de perda  $L$  definida como  $L_{i,t} = L(Y_t, \hat{Y}_{i,t})$ .

Pode ser definida assim a variável de performance relativa  $d_{ij,t} \equiv L_{i,t} - L_{j,t}$ , para todo  $i, j \in \mathcal{M}_0$ . Portanto, o conjunto de objetos superiores,  $\mathcal{M}^*$ , pode ser definido em função das perdas relativas:

$$\mathcal{M}^* \equiv \{i \in \mathcal{M}_0; E(d_{ij,t}) \leq 0 \text{ para todo } j \in \mathcal{M}_0\}$$

Em seqüência definimos por  $\mathcal{M}^c$  como o complemento de  $\mathcal{M}^*$ , e utilizamos  $i^c$  e  $i^*$ , respectivamente para representar os seus elementos.

Para determinar  $\mathcal{M}^*$ , é realizado uma seqüência de teste de significância, nos quais os objetos encontrados que são significativamente inferiores a outros elementos de  $\mathcal{M}_0$  são eliminados. A hipótese a ser testada leva a seguinte forma:

$$H_{0,\mathcal{M}} : E(d_{ij,t}) = 0 \text{ para todo } i, j \in \mathcal{M}, \text{ em que } \mathcal{M} \subset \mathcal{M}_0$$

contra a hipótese alternativa:

$$H_{A,\mathcal{M}} : E(d_{ij,t}) \neq 0 \text{ para algum } i, j \in \mathcal{M}, \text{ em que } \mathcal{M} \subset \mathcal{M}_0$$

O procedimento do MCS é baseado no teste de equivalência,  $\delta_{\mathcal{M}}$ , e uma regra de eliminação,  $e_{\mathcal{M}}$ . No teste de equivalência é utilizado o teste de hipótese apresentado acima,  $H_{0,\mathcal{M}}$ , para todo  $\mathcal{M} \subset \mathcal{M}_0$ , no qual a regra de eliminação,  $e_{\mathcal{M}}$ , identifica o objeto de  $\mathcal{M}$  que deve ser removido de  $\mathcal{M}$  no evento em que a  $H_{0,\mathcal{M}}$  é rejeitado. Sempre que  $\delta_{\mathcal{M}}$  é rejeitado toma o valor de 1, e quando aceito toma o valor de 0. Assim, o algoritmo do MCS é baseado nos três passos a seguir:

Passo 0: Defina o conjunto  $\mathcal{M} = \mathcal{M}_0$ .

Passo 1: Teste  $H_{0,\mathcal{M}}$  usando  $\delta_{\mathcal{M}}$  ao nível de significância  $\alpha$ .

Passo 2: Se  $H_{0,\mathcal{M}}$  é aceito, defini-se  $\widehat{\mathcal{M}}_{1-\alpha}^* = \mathcal{M}$ , caso contrário, usa-se  $e_{\mathcal{M}}$  para eliminar o objeto de  $\mathcal{M}$  e repete novamente o procedimento com início no passo 1.

Por fim, se obtêm o conjunto  $\widehat{\mathcal{M}}_{1-\alpha}^*$ , que consiste no conjunto de objetos “sobreviventes” a todos os testes, referido como o *Model Confidence Set*.

### 3.1.2 Como interpretar o p-valor do MCS

Para definir o p-valor do MCS, denote por  $m_0$  o número de modelos em  $\mathcal{M}_0$ . Para simplificação, suponha que os elementos de  $\mathcal{M}_0 = \{1, \dots, m_0\}$  são ordenados de forma que  $k = e_{\mathcal{M}(k)}$ , em que  $\mathcal{M}(k) = \{k, k + 1, \dots, m_0\}$ , com  $k = 1, \dots, m_0$ . Assim,  $e_{\mathcal{M}_0} = e_{\mathcal{M}(1)} = 1$  é o primeiro modelo a ser eliminado no evento de  $H_{0,\mathcal{M}(1)}$  ser rejeitado, enquanto  $e_{\mathcal{M}(2)} = 2$  é o próximo modelo, e assim por diante. Assim, define-se:

*Definição 3.1 (MCS p-valor).* Seja  $p(k)$  o p-valor da hipótese  $H_{0,\mathcal{M}(k)}$ , com a convenção de que  $p(m_0) \equiv 1$ . O p-valor do MCS para o modelo  $i \in \mathcal{M}_0$  é definido por  $\hat{p}_i \equiv \max_{k \leq i} p(k)$ .

A tabela abaixo descreve como o p-valor do MCS é definido e como o p-valor dos testes individuais,  $p(k), k = 1, \dots, m_0$ .

**Tabela 3.1 – ModelConfidence Set: p-valor**

$e_i$	p-valor do $H_{0,\mathcal{M}(k)}$	MCS p-valor
1	$p(1) = 0,01$	$\hat{p}_1 = 0,01$
2	$p(2) = 0,04$	$\hat{p}_2 = 0,04$
3	$p(3) = 0,02$	$\hat{p}_3 = 0,04$
4	$p(4) = 0,03$	$\hat{p}_4 = 0,04$
5	$p(5) = 0,07$	$\hat{p}_5 = 0,07$
6	$p(6) = 0,04$	$\hat{p}_6 = 0,07$
7	$p(7) = 0,11$	$\hat{p}_7 = 0,11$
8	$p(8) = 0,25$	$\hat{p}_8 = 0,25$
$\vdots$	$\vdots$	$\vdots$
$m_0$	$p(m_0) \equiv 1,00$	$\hat{p}_{m_0} = 1,00$

Fonte: Hansen et al (2010)

Desta forma, os p-valores do MCS são convenientes, pois é fácil de determinar se um objeto faz parte ou não do  $\hat{\mathcal{M}}_{1-\alpha}^*$ . A interpretação do p-valor do MCS é análogo ao p-valor em sua forma clássica. O MCS é um subconjunto variável de modelos que contém  $\mathcal{M}^*$  a uma certa probabilidade. A interpretação desta probabilidade do p-valor do MCS está ligada a natureza aleatória do MCS. A analogia a forma clássica é que para um intervalo de confiança de  $(1-\alpha)$  que contém o verdadeiro parâmetro com uma probabilidade não inferior a  $1-\alpha$ .

### 3.1.3 Testes de equivalência e regras de eliminação

Considere um teste de equivalência específico e uma regra de eliminação como em Hansen et al (2010). Seja  $\mathcal{M}$  um subconjunto de  $\mathcal{M}_0$ , e  $m$  o número de modelos em  $\mathcal{M} = \{i_1, \dots, i_m\}$ . Defina-se o vetor de variáveis de perda  $L_t \equiv (L_{i_1,t}, \dots, L_{i_m,t})'$ ,  $t = 1, \dots, n$ , e a sua média da amostra pode ser escrita como  $\bar{L} \equiv n^{-1} \sum_{t=1}^n L_t$ . Seja  $\iota \equiv (1, \dots, 1)'$  o vetor coluna onde todas as entradas  $m$  são iguais a 1, o complemento ortogonal de  $\iota$  é uma matriz  $m \times (m-1)$ ,  $\iota_{\perp}$ , de posto cheio e satisfaz  $\iota_{\perp}' \iota = 0$ . O vetor de dimensão  $m-1$ ,  $X_t \equiv \iota_{\perp}' L_t$  pode ser visto como  $m-1$  contrastes. Seja  $\mu \equiv E(X_t)$ , logo a hipótese nula  $H_{0,\mathcal{M}}$  é equivalente a  $\mu = 0$ , que assegura que  $n^{\frac{1}{2}}(\bar{X} - \mu) \sim N(0, \Sigma)$ , no qual  $\bar{X} \equiv n^{-1} \sum_{t=1}^n X_t$  e  $\Sigma \equiv \lim_{n \rightarrow \infty} \text{var}(n^{\frac{1}{2}} \bar{X})$ . Assim,  $H_{0,\mathcal{M}}$  pode ser testado usando o teste na forma quadrática tradicional, como aquelas baseadas nos testes estatísticos:

$$T_Q \equiv n \bar{X}' \hat{\Sigma}^{\#} \bar{X} \xrightarrow{d} \chi^2_{(q)} \quad \text{e} \quad T_f \equiv \frac{n-q}{q(n-1)} T_Q \xrightarrow{d} F_{(q, n-q)},$$

onde  $\hat{\Sigma}$  é um estimador consistente de  $\Sigma$ ,  $q \equiv \text{posto}(\hat{\Sigma})$ , e  $\hat{\Sigma}^{\#}$  é a inversa Moore-Penrose de  $\hat{\Sigma}$ . Assim,  $q$  denota o número efetivo de contrastes (o número de comparações linearmente independentes) sob  $H_{0,\mathcal{M}}$ .

Um problema empírico surge quando o número de elementos,  $m$ , se torna relativamente grande em relação ao tamanho da amostra. Neste caso, é útil considerar testes alternativos que não requerem uma estimativa da matriz de covariância,  $\Sigma$ ,  $(m-1) \times (m-1)$ . Estes testes podem ser construídos na forma de estatísticas  $t$ .

$$t_{ij} = \frac{\bar{d}_{ij}}{\sqrt{\widehat{\text{var}}(\bar{d}_{ij})}} \quad \text{e} \quad t_{i.} = \frac{\bar{d}_i}{\sqrt{\widehat{\text{var}}(\bar{d}_i)}}, \quad \text{para } i, j \in \mathcal{M},$$

onde se define  $\bar{d}_{ij} \equiv n^{-1} \sum_{t=1}^n d_{ij,t}$  e  $\bar{d}_i \equiv m^{-1} \sum_{j \in \mathcal{M}} \bar{d}_{ij}$ . A variável  $\bar{d}_{ij}$  mede a amostra do diferencial de perda entre o modelo  $i$  e  $j$ , enquanto,  $\bar{d}_i$  é o contraste das amostras de perda dos modelos  $i$ 's com a média de todos os modelos.

A hipótese nula,  $H_{0,\mathcal{M}}$ , é equivalente a  $E(\bar{d}_i) = 0$  para todo  $i \in \mathcal{M}$ , o que por definição é equivalente a  $E(\bar{d}_{ij}) = 0$  para todo  $i$  e  $j \in \mathcal{M}$ . A estatística de teste, como  $T_{max} = \max_{i \in \mathcal{M}} t_i$ ,  $T_D \equiv \sum_{i \in \mathcal{M}} t_i^2$ ,  $T_R \equiv \max_{i,j \in \mathcal{M}} |t_{ij}|$ , e  $T_{SQ} \equiv \sum_{i,j \in \mathcal{M}} t_{ij}^2$  podem ser usados para testa a hipótese nula. As estatísticas se referem ao desvio máximo, desvio padrão, amplitude e semi-quadrático, respectivamente.

A distribuição assintótica das estatísticas de teste,  $T_{max}$ ,  $T_D$ ,  $T_R$  e  $T_{SQ}$  são não padrões porque dependem da variância dos parâmetros sob a hipótese nula e alternativa. Entretanto, isso não é um grande obstáculo, pois as distribuições podem ser estimadas usando métodos de *bootstrap*, que podem ser vistos mais detalhadamente em Hansen et al (2010).

Para a estatística de teste  $T_{max}$  a regra de eliminação natural é  $e_{max,\mathcal{M}} \equiv \arg \max_{i \in \mathcal{M}} t_i$  porque a rejeição da hipótese nula identifica a hipóteses  $\mu_j = 0$  como falsa pra  $j = e_{max,\mathcal{M}}$ . Neste caso, a regra de eliminação remove o modelo que mais contribui para a estatística de teste. Este modelo tem a maior perda padronizada relativa a média de todos os modelos de  $\mathcal{M}$ .

### 3.2 MODELOS SARIMA (MODELO AUTORREGRESSIVO INTEGRADO DE MÉDIA MÓVEL COM SAZONALIDADE)

Os modelos ARIMA são métodos largamente discutidos na literatura, introduzidos inicialmente por Box e Jenkins (1976). Estes modelos também são frequentemente usados para séries com sazonalidade, o SARIMA, capturando a dinâmica não sazonal e sazonal das séries. A metodologia de Box e Jenkins (1976) pode ser dividida em três estágios: identificação, estimação e testes de adequação. É um processo iterativo, que quando um modelo não é escolhido, um novo ciclo de seleção se inicia e os mesmos passos são repetidos até que se encontre um modelo que se adeque aos dados.

Nos modelos estimados, além de dos componentes sazonais ARIMA, possibilitou-se também a existência de sazonalidade determinística, adicionando *dummies* sazonais. Assim, no processo de identificação do modelo, seria incorporado o tipo de sazonalidade que mais se adequa-se a série, ou até mesmo os dois tipos. O modelo estimado segue a forma:

$$\phi(L)\varphi(L^s)(\Delta y_t - \beta_1 D_1 - \dots - \beta_{12} D_{12}) = \theta(L)\delta(L^s)\varepsilon_t$$

Estes modelos foram estimados pelo software X-12 ARIMA disponibilizado pelo *United States Census Bureau*, utilizando o procedimento de seleção automática de modelos (*autmodl*) derivado daquele utilizado por TRAMO (Gómez e Maravall (2001)). No modelo também foi possibilitada a identificação automática de *outliers*<sup>2</sup>, a transformação da série (em logaritmo ou não) também foi definida de forma automática, e a quantidade de componentes autoregressivos ou média móvel foi limitada a 3, afim de evitar uma quantidade excessiva de parâmetros a serem estimados<sup>3</sup>. Os modelos foram selecionados pelos valores mais baixos segundo o critério de informação de Akaike (1973).

As séries estimadas por este procedimento foram as do número índice do IPCA “cheio”, para os 9 grupos, 52 itens, e para todas as classificações do Banco Central (12 novas séries), em um total de 74 modelos estimados.

### 3.3 MODELO ESTRUTURAL PARA SÉRIES DE TEMPO

Segundo Watson e Engle (1983), o uso de variáveis não observáveis em economia é amplamente aceito como uma abordagem útil para descrever fenômenos econômicos. A modelagem estrutural para séries de tempo tem como ideia geral que as séries são uma soma de componentes, não necessariamente observados, como tendência, sazonalidade, ciclos, em que cada um destes componentes evolui segundo uma determinada dinâmica. Os modelos estruturais em espaço-estado tornam-se uma abordagem bastante interessante para previsão ao

<sup>2</sup> Em alguns modelos foram utilizados critérios de identificação de outliers mais rigorosos a fim de evitar a excessiva identificação de outliers.

<sup>3</sup> A especificação do modelo, programada para o X-12 pode ser encontrada no Anexo I. Mais detalhes sobre o processo de seleção automática de modelos do X-12 ARIMA pode ser visto no manual de referência disponibilizado em <http://www.census.gov/srd/www/x12a/>.



permitir que os parâmetros possam ser estocásticos. Pode-se definir um modelo em espaço-estado da seguinte forma:

$$y_t = Z_t \alpha_t + \varepsilon_t \quad \varepsilon_t \sim N(0, H_t)$$

$$\alpha_{t+1} = T_t \alpha_t + R_t \eta_t \quad \eta_t \sim N(0, Q_t)$$

onde  $y_t$  é um vetor de observações  $p \times 1$ ;  $\alpha_t$  é chamado de vetor de estado, é não observado e possui dimensão  $m \times 1$ ;  $\varepsilon_t$  e  $\eta_t$  são termos de erro independentes. A estimação do modelo é feita pelo Filtro de Kalman combinado a máxima verossimilhança, no qual o erro de previsão é minimizado. O filtro de Kalman é composto por um conjunto de equações que estimam de forma recursiva no tempo a média e a variância condicional do vetor de estado. Iremos omitir os detalhes de estimação, que podem ser encontrados de forma mais detalhada em Durbin e Koopman (2004, cap. 4 e 7).

O modelo estrutural em espaço-estado que iremos estimar a inflação brasileira pode ser decomposto em tendência ( $\mu_t$ ), sazonalidade ( $\gamma_t$ ) e ciclo estocásticos ( $\psi_t$ ). Iremos realizar a estimação para a série de IPCA mensal utilizando o STAMP do Oxmetrics. Foi habilitada a identificação automática de *outliers*. O modelo estimado segue a forma do modelo estrutural básico com ciclo, que pode ser escrito da seguinte forma<sup>4</sup>:

$$y_t = \mu_t + \gamma_t + \psi_t + \varepsilon_t \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

$$\mu_t = \mu_{t-1} + \beta_{t-1} + v_t \quad v_t \sim N(0, \sigma_v^2)$$

$$\beta_t = \beta_{t-1} + \eta_t \quad \eta_t \sim N(0, \sigma_\eta^2)$$

$$\gamma_t = - \sum_{j=1}^{s-1} \gamma_{t-j} + \xi_t \quad \xi_t \sim N(0, \sigma_\xi^2)$$

sendo o ciclo estocástico  $\psi_t$  pode ser definido por

---

<sup>4</sup> O resultado do modelo para o último mês da amostra (março/12) pode ser encontrado no Anexo IV.

$$\begin{pmatrix} \psi_t \\ \psi_t^* \end{pmatrix} = \rho \begin{pmatrix} \cos \lambda_c & \text{sen } \lambda_c \\ -\text{sen } \lambda_c & \cos \lambda_c \end{pmatrix} \begin{pmatrix} \psi_{t-1} \\ \psi_{t-1}^* \end{pmatrix} + \begin{pmatrix} k_t \\ k_t^* \end{pmatrix}$$

onde  $k_t$  e  $k_t^*$  são perturbações mutuamente não-correlacionadas, com variância comum  $\sigma_k^2$ , e  $0 \leq \rho \leq 1$ .

### 3.4 MODELO MARKOV SWITCHING

Os modelos de mudança markoviana de regime são modelos não lineares de análise de séries de tempo, no qual existe uma probabilidade de transição entre regimes que está ligada ao período imediatamente anterior. Estes modelos são bastante úteis para modelar séries que apresentam períodos com comportamentos distintos. Por exemplo, não se deve esperar que uma economia em recessão se comporte da mesma forma que uma economia em um período de expansão. No caso da inflação, a hipótese de Friedman de que taxas de inflação mais altas levam ao aumento da volatilidade é a que mais se adequa a possibilidade de alternância de regimes de inflação. Esta não linearidade nas séries econômicas pode ser modelada a partir de modelos de mudança de regime. Para a série do IPCA, iremos utilizar um Markov-Switching autorregressivo, possibilitando dois regimes, sendo um para períodos em que a inflação é mais alta e outra para períodos de inflação baixa. Além disso, iremos incluir dummies para sazonalidade determinística no modelo. Vale notar que possibilitamos a existência de dois regimes na variância, ficando assim, de acordo com a hipótese de Friedman. O modelo estimado irá seguir a forma<sup>5</sup>:

$$y_t = \begin{cases} c_1 + \phi_1 y_{t-1} + \sum_{i=1}^{11} D_i + \varepsilon_{1t} & \text{se } s_t = 1 \\ c_2 + \phi_2 y_{t-1} + \sum_{i=1}^{11} D_i + \varepsilon_{2t} & \text{se } s_t = 2 \end{cases}$$

---

<sup>5</sup> O resultado do modelo estimado para o último mês da amostra pode ser encontrado no Anexo IV.

onde  $s_t$  assume valores  $\{ 1, 2 \}$  sendo definidas as seguintes probabilidades de transição entre os regimes:

$$P = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix}$$

Em que  $p_{ij}$  pode ser definido como a probabilidade do regime  $i$  ser seguido pelo regime  $j$ . O fenômeno é regido por um processo não observado em que as probabilidades tentam modelar a transição entre uma função condicional para outra. O processo de estimação do modelo depende da construção de uma função de verossimilhança e sua otimização utilizando um algoritmo similar ao proposto por Hamilton (1989). Primeiramente, otimiza-se a função de verossimilhança, seguido pelo cálculo das probabilidades filtradas e suavizadas, por fim, calculando os desvios padrões e as estatísticas para inferência.

### 3.5 TRATAMENTO DOS DADOS

As séries utilizadas para os modelos são as do IPCA, disponibilizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE), com início em janeiro de 1996 e término em março de 2012. Atualmente o IPCA possui as seguintes subdivisões, em ordem hierárquica: Grupos (9); Subgrupos (19); Itens (52); e Subitens (365)<sup>6</sup>. No entanto, as subdivisões do IPCA se alteram ao longo do tempo, após a divulgação da Pesquisa de Orçamento Familiares (POF) pelo IBGE, para que reflita de forma mais adequada as alterações nos padrões de consumo da população objetivo ao longo dos anos. Ao todo, ao longo de todo o período de divulgação do IPCA foram cinco mudanças na cesta de bens utilizada, sendo que dentro do período em análise do trabalho foram 3 alterações. As pesquisas de orçamento familiares que geraram as estruturas e os períodos de vigência dos pesos são listadas a seguir<sup>7</sup>:

---

<sup>6</sup> A abertura completa e a composição de cada uma das subdivisões do IPCA podem ser vistas no Anexo II.

<sup>7</sup> Ver Série de Relatórios Metodológicos do IBGE, Volume 14. Disponível em [ftp://ftp.ibge.gov.br/Precos\\_Indices\\_de\\_Precos\\_ao\\_Consumidor/Sistema\\_de\\_Indices\\_de\\_Precos\\_ao\\_Consumidor/Metodos\\_de\\_calculo/Metodos\\_de\\_Calculo\\_5ed.zip](ftp://ftp.ibge.gov.br/Precos_Indices_de_Precos_ao_Consumidor/Sistema_de_Indices_de_Precos_ao_Consumidor/Metodos_de_calculo/Metodos_de_Calculo_5ed.zip)

- ✓ com base no ENDEF 1974-1975<sup>8</sup>, pesos vigentes de 1979 a maio de 1989;
- ✓ com base na POF 1987-1988, estrutura implantada em junho de 1989, vigente até julho de 1999;
- ✓ com base na POF 1995-1996, ponderações implantadas em agosto de 1999, estando em vigor até junho de 2006;
- ✓ com base na POF 2002-2003, implantação a partir de julho de 2006 e vigente até dezembro de 2011;
- ✓ com base na POF 2008-2009, implantada a partir de janeiro de 2012.

A alteração mais recente da estrutura de ponderação se deu em janeiro de 2012 e apresentou uma redução na quantidade de subitens de 384 para os 365 atuais, devido a inclusão de 31 subitens e exclusão de 50, sem que ocorressem alterações nas demais subdivisões, ou seja, foram mantidos os 9 grupos e os 52 itens. Porém, as alterações anteriores apresentaram mudanças mais significativas. Decidiu-se por compatibilizar as séries de grupos e itens do IPCA para a abertura mais atual, utilizando-se o tradutor das estruturas do IBGE. Assim, trabalhou-se com 9 grupos e 52 itens nas projeções nos níveis mais desagregados, por sofrer um menor número de alterações ao longo do período em análise, sendo mais fácil a sua compatibilização. Para apenas dois dos itens atuais não há estrutura correspondente para o período entre janeiro de 1991 a julho de 1999, começando, portanto, em agosto de 1999. São eles: Consertos e manutenção (código 3301) e Plano de saúde (código 6203). Os demais itens que sofreram alterações, mas puderam ser compatibilizados tornando a série completa são: Fotografia e Filmagem (código 7203); Recreação (código 7201); Cursos (código 8101); Cursos diversos (código 8104); Papelaria (código 8103) e Comunicação (código 9101). Mais detalhes sobre a compatibilização dos dados e alteração das estruturas do IPCA ao longo do tempo pode ser vista no ANEXO III.

Na Tabela 3.2 abaixo, pode-se observar as alterações dos pesos para cada um dos grupos em todas as alterações da POF, na data da primeira divulgação com os pesos novos. As principais alterações, como se pode observar foram no grupo Educação que passou de 4,97% em agosto de 1999 para 7,12% em julho de 2006 e depois caiu novamente para 4,37% em janeiro de 2012. O grupo comunicação também sofreu alterações significativas, ao sair de 0,73% em janeiro de 1996 para 3,41% em agosto de 1999, passando para 6,56% em julho de

---

<sup>8</sup> Estudo Nacional de Despesa Familiar – ENDEF 1974-1975 foi a primeira “pesquisa de orçamento familiar” realizada pelo IBGE.

2006 e 4,96% em janeiro de 2012. Também chama a atenção a forte queda no peso do grupo Vestuários ao sair de 10,37% em janeiro de 1996 para 5,68% em agosto de 1999.

**Tabela 3.2 – Pesos Grupos IPCA nas alterações da POF**

<b>Pesos oficiais para os grupos na data de incorporação dos pesos atualizados pela POF (%)</b>				
	<b>jan/96<sup>1</sup></b>	<b>ago/99</b>	<b>jul/06</b>	<b>jan/12</b>
0 IPCA	100.00	100.00	100.00	100.00
1 Alimentação e bebidas	26.54	22.30	20.29	23.12
2 Habitação	14.51	16.29	13.71	14.62
3 Artigos de residência	7.44	5.98	4.84	4.68
4 Vestuário	10.37	5.68	6.52	6.67
5 Transportes	16.04	19.99	20.96	20.54
6 Saúde e cuidados pessoais	9.43	11.47	10.75	11.09
7 Despesas pessoais	11.15	9.90	9.26	9.94
8 Educação	3.79	4.97	7.12	4.37
9 Comunicação	0.73	3.41	6.56	4.96

1- Pesos de janeiro de 1996, mas a alteração da POF foi em janeiro de 1991

Fonte: IBGE

Outra forma de analisar o IPCA de forma desagregada seria utilizando-se o sistema de classificação dos itens do Banco Central do Brasil (BCB), que seguem critérios internacionais recomendados pela Organização das Nações Unidas (ONU). Neste sentido, o BCB divulga os itens que compõem as seguintes classificações: serviços, bens duráveis, bens não duráveis, bens semiduráveis, comercializáveis, não comercializáveis, administrados. Com a alteração da POF em janeiro de 2012, o BCB também realizou algumas alterações nas classificações anteriores, e como o objetivo do trabalho é testar as melhores desagregações para projeção de inflação, decidiu-se fazer as projeções tanto nas classificações antigas como nas novas.

As principais diferenças entre a classificação atual e anterior do BCB estão nos grupos de serviços e administrados. Na classificação nova, passa a fazer parte dos serviços o subgrupo “Alimentação fora do domicílio” (peso de 7,97% do IPCA em jan-12) e o subitem “Passagem aérea” (peso de 0,57% em jan-12). Nos administrados saiu o subitem “Passagem aérea” e também o subitem “Telefone celular” (peso de 1,52% do IPCA em jan-12). Estas alterações são significativas, pois o subgrupo “Alimentação fora do domicílio”, apesar de ser um serviço, pode sofrer uma grande influência da variação dos preços dos alimentos, que são

mais voláteis, alterando a dinâmica da série. Além disso, o subitem “Passagem aérea”, passou por uma mudança de metodologia de cálculo relativamente recente (fevereiro de 2010), que levou a um aumento da volatilidade do subitem, que apesar do peso pequeno, devido suas altas taxas de variação mês a mês, pode influir de forma significativa no resultado final do grupo. Desta forma, enquanto o grupo de Serviços tem peso de 33,72% na nova classificação em janeiro de 2012, na classificação antiga teria 23,66% para o mesmo período. Na Tabela 3.3 pode-se observar as alterações de pesos em cada momento de alteração das estruturas do IPCA devido a mudança da POF<sup>9</sup>. Uma das classificações que mais chama a atenção é a de preços administrados que apresenta grande variação de peso ao longo do período. No início do período em análise, em janeiro de 1996, o peso dos administrados era de apenas 13,25%, chegando a alcançar 31,29% em julho de 2006, mas foi bastante reduzido na última alteração de peso para 26,70% em janeiro de 2012.

**Tabela 3.3 – Pesos IPCA das Classificações do BCB nas alterações da POF**

<b>Pesos para as classificações do IPCA na data de incorporação dos pesos atualizados pela POF (%)</b>				
	<b>jan/96<sup>1</sup></b>	<b>ago/99</b>	<b>jul/06</b>	<b>jan/12</b>
Alimentação e bebidas	26.54	22.30	20.29	23.12
Serviços	30.43	24.33	23.06	23.66
Administrados	13.25	24.40	31.19	26.70
Industrializados	29.79	28.97	25.46	26.52
<b>IPCA</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>
Alimentação no domicílio	18.88	17.15	13.36	15.15
Administrados novo	13.22	26.61	29.31	24.51
Serviços novo	37.53	29.48	31.38	33.72
Industrializados novo	30.37	26.76	25.94	26.62
<b>IPCA</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>
Serviços	30.43	24.33	23.06	23.66
Administrados	13.25	24.40	31.19	26.70
Bens duráveis	8.25	11.55	10.67	11.56
Bens não duráveis	33.56	31.99	26.04	29.51
Bens semiduráveis	14.51	7.72	9.03	8.56
<b>IPCA</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>
Comercializáveis	43.92	39.97	33.44	36.13
Não comercializáveis	42.83	35.63	35.37	37.16
Administrados	13.25	24.40	31.19	26.70
<b>IPCA</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>

Fonte: IBGE; Banco Central do Brasil; Elaboração do autor

<sup>9</sup> Os detalhes das classificações do BCB e as diferenças em relação a nova classificação estão no Anexo II

Assim, iremos trabalhar as projeções do IPCA com as seguintes desagregações, nas quais utilizaremos os nomes definidos na Tabela 3.4. Para os modelos no nível agregado, a fins de comparação utilizaremos a metodologia de espaço-estado e de mudança markoviana de regime, conforme discutido nas seções anteriores. Uma vantagem de se trabalhar com os preços desagregados, nestes casos, também se devem as mudanças de pesos nas estruturas, que podem ser melhor controladas desta forma.

**Tabela 3.4 – Modelos estimados e suas desagregações**

<b>Sigla</b>	<b>Composição</b>	<b>Modelo</b>
IPCA	Índice geral	SARIMA
IPCA_Grupos	9 grupos	SARIMA
IPCA_Itens	52 itens	SARIMA
IPCA_Ind	Industrializados, serviços, administrados e grupo alimentação e bebidas	SARIMA
IPCA_Trad	Comercializáveis, não comercializáveis, administrados	SARIMA
IPCA_Dur	Duráveis, semiduráveis, não duráveis, serviços e administrados antigo	SARIMA
IPCA_IndNovo	Industrializados novo, serviços novo, administrados novo e subgrupo alimentação no domicílio	SARIMA
IPCA_MS	Índice geral	Markov-Switching
IPCA_FK	Índice geral	Modelo estrutural

Fonte: Elaboração do autor

Nota: No Anexo II estão as aberturas detalhadas de todas as classificações

## 4 RESULTADOS

A avaliação do desempenho dos modelos foi realizada através dos resultados fora da amostra para as projeções de até doze meses à frente. Todas as séries e modelos foram estimados de maneira recursiva, com início em janeiro de 2008 e fim em março de 2012. Isso significa que a cada nova informação adicionada os modelos e todos os seus parâmetros foram reestimados a fim de obter sempre o “melhor” modelo, condicionado a informação naquele período. Neste sentido, a amostra para cada um dos períodos de estimação varia de acordo com o final da amostra, ou seja, para a avaliação das projeções dos modelos um passo a frente a amostra é de 51 meses, enquanto para as projeções doze meses a frente a amostra é de 40. Preferiu-se utilizar a amostra completa para cada horizonte de projeção, pois quanto mais informativa for a série, melhor será o resultado encontrado no MCS.

Nos modelos desagregados, os seus subcomponentes foram reagregados utilizando-se os pesos correspondentes para o IPCA para o primeiro mês projetado, enquanto para os demais meses à frente, os pesos foram estimados baseado no resultado da projeção no período imediatamente anterior.

A função de perda utilizada para comparação das projeções entre os modelos foi o *Erro Quadrático Médio da projeção (EQM)* que pode ser definido como a média entre diferença do valor estimado e o verdadeiro, elevado ao quadrado. A vantagem desta medida é que os maiores desvios de projeção recebem a maior punição. Vale lembrar que o EQM foi calculado em cima do número índice e não em relação a taxa de variação, por isso os resultados que serão apresentados mais adiante apresentam valores absolutos relativamente grandes do que se comparado em termos percentuais.

A Tabela 4.1 abaixo mostra o EQM para todos os modelos nas projeções até doze meses à frente. Os modelos estão ordenados do menor nível de desagregação para a maior desagregação possível. Os menores EQM foram encontrados nos modelos com o maior nível de desagregação, pois o modelo feito através da projeção dos 52 itens do IPCA é a que apresentou o EQM mais baixo, seguido da subdivisão por grupos. O terceiro menor EQM foi do IPCA subdividido em 4 grandes grupos: Alimentação e bebidas, industrializados, serviços e administrados. Os maiores EQM's foram encontrados nos modelos agregados nos três métodos de projeção utilizados (SARIMA, Markov-Switching, Modelo estrutural).



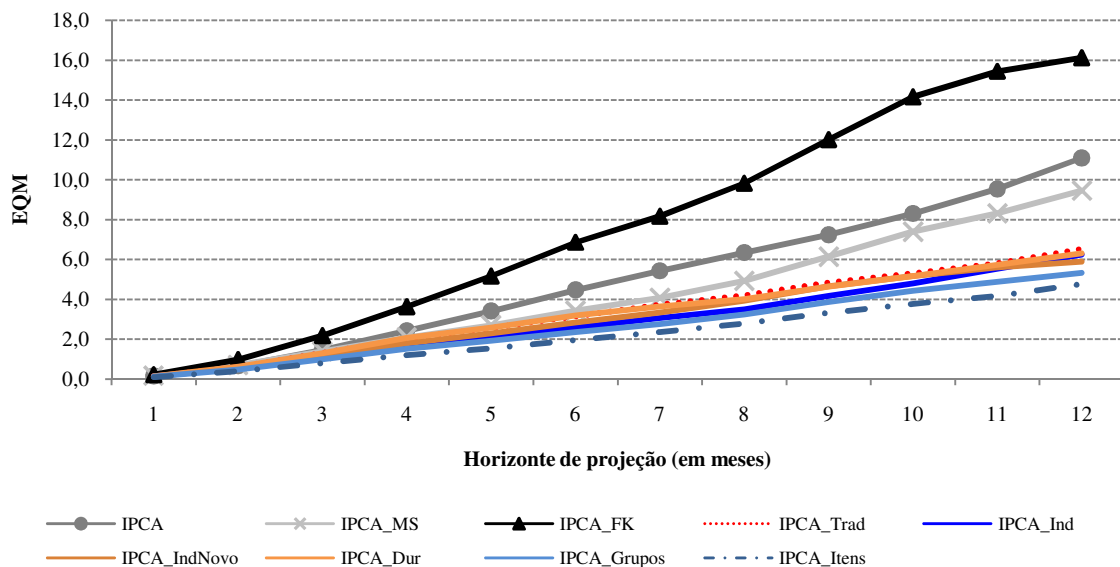
**Tabela 4.1 – Erro Quadrático Médio dos modelos por horizonte de projeção**

	Horizonte de projeção (em meses)											
	1	2	3	4	5	6	7	8	9	10	11	12
IPCA	0.146	0.662	1.461	2.422	3.409	4.469	5.423	6.342	7.231	8.298	9.529	11.089
IPCA_MS	0.176	0.705	1.396	2.089	2.701	3.430	4.072	4.921	6.138	7.388	8.313	9.447
IPCA_FK	0.216	0.977	2.183	3.625	5.170	6.856	8.166	9.821	12.010	14.162	15.438	16.121
IPCA_Trad	0.140	0.613	1.306	2.021	2.559	3.132	3.742	4.193	4.840	5.311	5.803	6.526
<b>IPCA_Ind</b>	<b>0.134</b>	<b>0.541</b>	<b>1.050</b>	<b>1.732</b>	<b>2.085</b>	<b>2.582</b>	<b>3.055</b>	<b>3.497</b>	<b>4.172</b>	<b>4.798</b>	<b>5.535</b>	<b>6.237</b>
IPCA_IndNovo	0.143	0.553	1.127	1.790	2.293	2.838	3.341	3.941	4.655	5.171	5.601	5.893
IPCA_Dur	0.143	0.633	1.303	2.062	2.583	3.200	3.646	4.010	4.641	5.170	5.725	6.307
IPCA_Grupos	<b>0.128</b>	<b>0.482</b>	<b>0.988</b>	<b>1.517</b>	<b>1.928</b>	<b>2.365</b>	<b>2.764</b>	<b>3.240</b>	<b>3.876</b>	<b>4.439</b>	<b>4.880</b>	<b>5.331</b>
IPCA_Itens	<b>0.098</b>	<b>0.408</b>	<b>0.811</b>	<b>1.201</b>	<b>1.541</b>	<b>1.953</b>	<b>2.352</b>	<b>2.788</b>	<b>3.312</b>	<b>3.766</b>	<b>4.173</b>	<b>4.763</b>

Fonte: Elaboração do autor

Nota: Em negrito os três modelos com os menores Erros Quadráticos Médios

A análise inicial dos dados sugere um melhor desempenho nas projeções dos modelos mais desagregados, enquanto os modelos agregados apresentaram os piores resultados. Graficamente, fica ainda mais claro o baixo desempenho dos modelos agregados em relação aos modelos desagregados (Figura 4.1), sendo que o modelo estimado pela metodologia de espaço-estado apresenta o pior resultado entre todos os modelos.

**Figura 4.1 – Erro quadrático médio de projeção dos modelos estimados por horizonte de projeção**

#### 4.1 RESULTADOS DO MCS

No entanto, apenas a análise do EQM não nos diz se as diferenças encontradas nos resultados dos modelos são significantes estatisticamente, ou se a amostra no período é informativa o suficiente para se definir um melhor modelo. Assim, iremos realizar testes estatísticos para verificar quais são os modelos que podem ser considerados melhores estatisticamente pelo critério de seleção de modelo *Model Confidence Set*. Na Tabela 4.2 estão todos os p-valores resultantes do MCS e também os modelos considerados como parte do conjunto de “melhores” modelos ( $\mathcal{M}^*$ ) com 90% e 75% de probabilidade, indicados com um e dois asteriscos, respectivamente, assim como realizado em Hansen et AL (2010).

Os resultados encontrados sugerem que há um ganho precisão nas projeções nos modelos com maior nível de desagregação, pois o IPCA projetado nos 52 itens aparece no  $\hat{\mathcal{M}}_{90\%}^*$  em todos os horizontes de projeção. Nas projeções com 5, 6, 9 e 11 meses a frente, este modelo aparece como único modelo pertencente ao  $\mathcal{M}^*$ . Outra evidência que também sugere ganho na desagregação é que o modelo com o segundo maior grau de desagregação, o IPCA projetado em todos os 9 grupos, aparece no  $\mathcal{M}^*$  em 8 dos 12 horizontes de projeção, sendo que para 1, 2, 3 e 12 meses aparece com 90% de probabilidade, enquanto para 4, 7, 8 e 10 meses aparece com 75%. Os modelos agregados aparecem com a menor frequência no MCS, sendo que a estimativa do modelo estrutural não pertenceu a  $\mathcal{M}^*$  para nenhum horizonte de projeção, enquanto o Markov-switching e o SARIMA aparecem em  $\mathcal{M}^*$  na projeção 1, 7 e 8 meses a frente.

**Tabela 4.2 – Model Confidence Set e p-valor dos modelos estimados**

	Horizonte de projeção (em meses)											
	1	2	3	4	5	6	7	8	9	10	11	12
Amostra (n)	51	50	49	48	47	46	45	44	43	42	41	40
IPCA	0.3144*	0.0322	0.042	0.0215	0.0314	0.0588	0.1031**	0.119**	0.0993	0.0711	0.0311	0.0197
IPCA_MS	0.1366**	0.0458	0.0422	0.0215	0.0314	0.0588	0.1031**	0.119**	0.0993	0.0711	0.0311	0.0197
IPCA_FK	0.0454	0.0237	0.042	0.0215	0.028	0.0401	0.0769	0.0269	0.0181	0.0168	0.0176	0.0119
IPCA_Trad	0.4193*	0.1044**	0.0809	0.0215	0.0314	0.0759	0.1031**	0.119**	0.0993	0.1024**	0.0485	0.0584
IPCA_Ind	<b>0.4727*</b>	<b>0.4634*</b>	<b>0.3093*</b>	<b>0.0792</b>	<b>0.0657</b>	<b>0.0759</b>	<b>0.1031**</b>	<b>0.119**</b>	<b>0.0993</b>	<b>0.1024**</b>	<b>0.0485</b>	<b>0.1163**</b>
IPCA_IndNovo	0.3144*	0.4634*	0.266*	0.0515	0.0391	0.0759	0.1031**	0.119**	0.0993	0.1024**	0.0485	0.1014**
IPCA_Dur	0.4193*	0.1959**	0.0527	0.0215	0.0314	0.0588	0.1031**	0.119**	0.0993	0.1024**	0.0485	0.1606**
IPCA_Grupos	<b>0.4727*</b>	<b>0.4634*</b>	<b>0.3093*</b>	<b>0.1439**</b>	<b>0.0936</b>	<b>0.0759</b>	<b>0.1067**</b>	<b>0.119**</b>	<b>0.0993</b>	<b>0.1024**</b>	<b>0.06</b>	<b>0.3202*</b>
IPCA_Itens	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>	<b>1.0000*</b>

Nota 1: Os modelos com um asterisco pertencem ao MCS com 90% de probabilidade, enquanto os modelos com dois asteriscos tem probabilidade de 75%.

Nota 2: Em negrito, os três modelos com menores EQM identificados anteriormente

Fonte: Elaboração do autor

É bastante interessante notar os ganhos apresentados nos modelos desagregados ocorrem em todos os horizontes de projeção, ou seja, tanto no curto prazo como em prazos mais longos. Deve-se observar que o p-valor encontrados nos modelos desagregados são os mais elevados, sendo que a projeção no maior nível desagregação aparece com p-valor igual a 1 em todos os 12 horizontes de projeção.

Vale lembrar que todos os modelos estimados são univariados, e que os modelos multivariados podem apresentar um ganho adicional. A análise dos modelos multivariados fica como sugestão de estudos futuros no tema.

#### 4.2 COMPARAÇÃO MCS COM O TESTE DE DIEBOLD & MARIANO (1995)

A metodologia de Diebold-Mariano (DM) para comparação de modelos, necessita de um modelo benchmark para a comparação par a par dos modelos de projeção. Optou-se por utilizar como modelo benchmark o IPCA projetado pelos 52 itens (IPCA\_Itens), já que encontramos evidência de ganhos de precisão nas projeções utilizando o modelos mais desagregado. Assim, compararemos o os erros quadráticos médio de projeção do IPCA\_Itens contra todos os demais modelos, verificando se os ganhos são estatisticamente significantes por DM. O teste proposto por DM tem como hipótese nula igualdade de desempenhos de projeção. A estatística de teste é definida por:

$$S_1 = \frac{\bar{d}}{\sqrt{\frac{2\pi\hat{f}_d(0)}{T}}}$$

onde:

$d = g(e_{it}) - g(e_{jt})$ , é o diferencial da função de perda;

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T (g(e_{it}) - g(e_{jt}));$$

$f_d(0) = \frac{1}{2\pi} \sum_{\tau=-\infty}^{\infty} \gamma_d(\tau)$ ,  $\hat{f}_d(0)$  é um estimador consistente de  $f_d(0)$ ;

$\gamma_d(\tau) = E((d_t - \mu)(d_{t-\tau} - \mu))$  e

$$\sqrt{T}(\bar{d} - \mu) \xrightarrow{d} N(0, 2\pi f_d(0)).$$

Desta forma, testa-se a hipótese nula  $E[d_t] = 0$ , ou seja, se o diferencial da função de perda é ou não significativo. Na Tabela abaixo, colocamos todos os testes realizados, utilizando o modelo IPCA\_Itens como benchmark, e pode se observar que também pelo teste DM, há evidências de ganho de desempenho de projeção para os modelos mais desagregados. Nos horizontes mais curtos de projeção, até 7 meses a frente, apenas o modelo de IPCA por grupos (IPCA\_Grupos) é equivalente estatisticamente a pelo menos 10% de significância em relação ao benchmark, com exceção da projeção com 4 meses à frente. Todos os demais modelos são inferiores ao modelo IPCA\_Itens a 10% de significância. Nos horizontes mais longos, não há evidências tão claras de ganho de desagregação, sendo que o único modelo que perde em desempenho de projeção em todos os horizontes de previsão é o modelo estrutural.

**Tabela 4.3 – Diebold-Mariano teste do modelo mais desagregado em relação dos demais, por horizonte de tempo**

	Horizonte de projeção (em meses)											
	1	2	3	4	5	6	7	8	9	10	11	12
Amostra (n)	51	50	49	48	47	46	45	44	43	42	41	40
IPCA	-0,05** (0,0213)	-0,25** (0,1)	-0,65** (0,2587)	-1,22** (0,4576)	-1,87** (0,7327)	-2,52** (1,1277)	-3,07* (1,6273)	-3,55 (2,1543)	-3,92 (2,6388)	-4,53 (2,9898)	-5,36 (3,2435)	-6,33* (3,537)
IPCA_MS	-0,12** (0,0526)	-0,37** (0,1461)	-0,7** (0,2646)	-1,11** (0,4281)	-1,47** (0,6557)	-1,8* (0,9244)	-2,09* (1,216)	-2,52 (1,5488)	-3,2 (2,0148)	-4,11 (2,6423)	-4,69 (3,1509)	-5,2 (3,7217)
IPCA_FK	-0,12*** (0,0302)	-0,57*** (0,1476)	-1,37*** (0,3571)	-2,42*** (0,5822)	-3,63*** (0,7863)	-4,9*** (1,1404)	-5,81*** (1,6831)	-7,03*** (2,3134)	-8,7*** (3,0126)	-10,4*** (3,702)	-11,26*** (4,1382)	-11,36** (4,4587)
IPCA_Trad	-0,04** (0,0201)	-0,2** (0,091)	-0,49** (0,2189)	-0,82** (0,3398)	-1,02** (0,444)	-1,18** (0,5676)	-1,39* (0,7678)	-1,41 (0,9645)	-1,53 (1,1568)	-1,55 (1,2641)	-1,63 (1,2799)	-1,76 (1,3427)
IPCA_Ind	-0,04* (0,0177)	-0,13** (0,0652)	-0,24* (0,1234)	-0,53** (0,1991)	-0,54** (0,2424)	-0,63* (0,3226)	-0,7* (0,4122)	-0,71 (0,4724)	-0,86 (0,5452)	-1,03 (0,6461)	-1,36* (0,7468)	-1,47 (0,8762)
IPCA_IndNovo	-0,04** (0,0221)	-0,14* (0,0854)	-0,32* (0,1643)	-0,59** (0,239)	-0,75** (0,2828)	-0,89** (0,3721)	-0,99** (0,4824)	-1,15* (0,5948)	-1,34* (0,7519)	-1,4 (0,9221)	-1,43 (1,0603)	-1,13 (1,0619)
IPCA_Dur	-0,05** (0,0169)	-0,22*** (0,0815)	-0,49** (0,1922)	-0,86*** (0,305)	-1,04*** (0,3752)	-1,25*** (0,4548)	-1,29** (0,5382)	-1,22** (0,5825)	-1,33* (0,6911)	-1,4 (0,862)	-1,55 (1,1041)	-1,54 (1,4049)
IPCA_Grupos	-0,03 (0,0187)	-0,07 (0,0623)	-0,18 (0,1231)	-0,32* (0,1783)	-0,39 (0,2404)	-0,41 (0,2921)	-0,41 (0,3457)	-0,45 (0,3919)	-0,56 (0,4362)	-0,67 (0,5202)	-0,71 (0,5714)	-0,57 (0,7009)

Nota: Os coeficientes são a constante do resultado da regressão da diferença entre a série de EQM de projeção do modelo mais desagregado (IPCA\_Itens) em relação aos demais modelos em função de uma constante. O \*\*\* representa o nível de significância de 1%; \*\* nível de significância de 5%; e \* sinificante a 10%.

## 5 POSSÍVEIS EXTENSÕES E LIMITAÇÕES DO TRABALHO

O trabalho analisa previsões a partir de um nível de desagregação mais ampla nos modelos de inflação do Brasil, além de introduzir uma técnica recente de comparação de modelos de projeção apresentado por Hansen et al (2010). Apesar disto, apresenta algumas limitações e possibilidades diversas de extensões para os estudos futuros. Uma das limitações do estudo se encontra na amostra relativamente curta em termos históricos, principalmente quando se considera que as projeções se iniciaram em janeiro de 2008, perdendo-se assim 51 dados, e com alguns períodos turbulentos devido à mudança de regime cambial em janeiro de 1999 e a desvalorização cambial relevante em 2002. Outra observação deve ser feita em relação ao período de projeção, que incorpora diversos choques exógenos, como a crise financeira que teve como principal evento a quebra do Lehman Brothers em setembro de 2008, a forte alta no preço de commodities em 2010, reflexo das políticas monetárias frouxas nos países desenvolvidos, e a crise das dívidas européias, com o primeiro pedido de resgate da Grécia ao FMI em abril de 2010. Ainda em relação ao período de projeção, este gerou uma amostra relativamente curta de erros quadráticos médios, de 51 dados para a projeção 1 mês a frente e 40 dados para 12 meses a frente, o que pode prejudicar a avaliação quanto a real diferença de precisão nos modelos estudados, muito embora, uma das vantagens do MCS seja reconhecer as limitações dos dados, e caso estes não sejam muito explicativos, gerariam um MCS com todos os modelos. Assim, uma possível extensão ao trabalho seria realizar o mesmo exercício de previsão para diferentes períodos da série do IPCA, afim de se observar se resultados semelhantes são obtidos nos demais períodos.

Outra extensão possível ao trabalho seria a incorporação de uma maior gama de modelos de previsão, incluindo modelos multivariados como VAR, modelos de curva de Phillips agregados e desagregados e modelos fatoriais. Em relação ao modelo com maior nível de desagregação, IPCA Itens, seria possível estimar cada um dos itens com o modelo que melhor se ajusta a série, e não apenas modelos lineares da classe SARIMA, o que poderia levar a um ganho ainda maior na desagregação dos dados.

Existe uma gama bastante grande de possíveis extensões ao trabalho que poderiam resultar em ganhos adicionais para a pesquisa de metodologias de projeção de inflação brasileira.

## 6 CONCLUSÃO

Este trabalho apresentou uma comparação das previsões de inflação até 12 meses a frente, medido pelo IPCA, utilizando modelos univariados lineares e não lineares de séries de temporais, projetando os índices a partir de informação agregada e desagregada. A comparação do desempenho das previsões foi realizado pelo *Model Confidence Set*, introduzido por Hansen et al (2010), pelo qual foi verificado que existem ganhos significativos nas projeções desagregadas de inflação, de forma mais clara para horizontes de previsão mais curtos, e de forma menos significativa para os horizontes mais longos. A análise pelo EQM e pelo p-valor do MCS sugere que até para horizontes mais longos, há ganho de desempenho na desagregação, muito embora estes não tenham se mostrado significativos estatisticamente. Um dos fatores que podem ter limitado que os resultados se mostrassem significativos também para horizontes mais longos se deve a amostra relativamente curta tanto no modelo de projeção dentro da amostra como para as previsões fora da amostra. Os modelos não lineares estimados para o IPCA agregado, *Markov-switching* e Modelo estrutural, apresentaram os piores resultados entre os modelos. O pior desempenho de previsão foi apresentado pelo Modelo estrutural, sugerindo que os modelos com coeficientes estocásticos podem gerar ganhos dentro da amostra, que não são verificados fora da amostra.

O resultado encontrado na seção anterior, de certa forma, é semelhante ao encontrado em alguns trabalhos internacionais, nos quais se evidenciou ganhos na desagregação nas projeções, como Duarte e Rua (2007) que encontraram uma relação inversa entre quantidade de informação e horizonte de previsão, ou seja, os modelos mais desagregados apresentaram melhor poder preditivo nos prazos mais curtos. Hendry e Hubrich (2006) também encontraram ganhos na desagregação para projeção de inflação da Zona do Euro. Sachsida, Ribeiro e Dos Santos (2009) encontraram pouca adequabilidade do modelo *Markov-switching* para projeção da inflação trimestral brasileira.

O trabalho procura contribuir a literatura ressaltando que a análise desagregada dos índices de preços pode gerar previsões mais adequadas. Os resultados são mais fortes para horizontes de previsão mais curtos.

## ANEXOS

### Anexo I – Especificação dos modelos estimados no X-12 ARIMA

Utilizado em todas as séries estimadas por SARIMA, exceto nos mencionados abaixo, em a especificação não se mostrou adequada devido ou a identificação excessiva de *outliers* ou por não comportar sazonalidade determinística no modelo.

```
series { start=1996.1
        period=12
        decimals = 2 }
transform { function = auto }
regression { variables= ( seasonal ) }
automdl { maxorder = (3 1)
         savelog = automodel }
outlier { types = all }
forecast { maxlead = 12 }
estimate { maxiter = 5000000 }
```

A especificação abaixo foi utilizada para as séries com identificação de um número excessivo de *outliers*, onde definiu-se um valor crítico mais elevado. São elas: Serviços, Semiduráveis; e os itens 7202, 6202 e 8101.

```
series { start=1996.1
        period=12
        decimals = 2 }
transform { function = auto }
regression { variables= ( seasonal ) }
automdl { maxorder = (3 1)
         savelog = automodel }
outlier { types = all
        critical = 6.0 }
forecast { maxlead = 12 }
estimate { maxiter = 5000000 }
```



A especificação abaixo foi utilizada para as séries que não comportaram sazonalidade determinística. São os itens: 1114, 1105, 2202, 3101, 3103, 3301, 4101, 4103, 4201, 4301, 6203, 7101, 7201, 8103 e 8104. E grupos: 8 e 7.

```
series { start=1996.1
         period=12
         decimals = 2 }
transform { function = auto }
regression { variables= () }
automdl { maxorder = (3 1)
         savelog = automodel }
outlier { types = all }
forecast { maxlead = 12 }
estimate { maxiter = 5000000 }
```

## Anexo II - Estrutura de ponderação – IPCA – Brasil – janeiro 2012

Código	Descrição	Peso	IPCA_Dur	IPCA_Trad	IPCA_Ind	IPCA_IndNovo
<b>0</b>	<b>Índice Geral</b>	<b>100,0000</b>	-	-	-	-
<b>1</b>	<b>Alimentação e bebidas</b>	<b>23,1237</b>	-	-	-	-
<b>11</b>	<b>Alimentação no domicílio</b>	<b>15,1526</b>	-	-	-	-
<b>1101</b>	<b>Cereais, leguminosas e oleaginosas</b>	<b>0,8218</b>	-	-	-	-
1101002	Arroz	0,5054	NDur	TRAD	ALIM	ALIMD
1101051	Feijão-mulatinho	0,0216	NDur	NTRAD	ALIM	ALIMD
1101052	Feijão-preto	0,0537	NDur	NIHAD	ALIM	ALIMD
1101053	Feijão-macassar (tradinho)	0,0336	NDur	NIHAD	ALIM	ALIMD
1101073	Feijão-carioca (rajado)	0,2074	NDur	NTRAD	ALIM	ALIMD
<b>1102</b>	<b>Farinhas, teculas e massas</b>	<b>0,6050</b>	-	-	-	-
1102001	Farinha de arroz	0,0109	NDur	IHAD	ALIM	ALIMD
1102006	Macarrão	0,2698	NDur	TRAD	ALIM	ALIMD
1102008	Fubá de milho	0,0258	NDur	TRAD	ALIM	ALIMD
1102009	Amido de milho	0,0046	NDur	NTRAD	ALIM	ALIMD
1102010	Hocos de milho	0,0049	NDur	NIHAD	ALIM	ALIMD
1102012	Farinha de trigo	0,0742	NDur	TRAD	ALIM	ALIMD
1102013	Farinha vitamizada	0,0078	NDur	TRAD	ALIM	ALIMD
1102023	Farinha de mandioca	0,1060	NDur	NIHAD	ALIM	ALIMD
1102029	Massa semipreparada	0,1011	NDur	IHAD	ALIM	ALIMD
<b>1103</b>	<b>Tubérculos, raízes e legumes</b>	<b>0,5333</b>	-	-	-	-
1103003	Batata-inglesa	0,1399	NDur	NTRAD	ALIM	ALIMD
1103004	Inhame	0,0078	NDur	NIHAD	ALIM	ALIMD
1103005	Mandioca (aipim)	0,0082	NDur	NIHAD	ALIM	ALIMD
1103017	Abóbora	0,0115	NDur	NIHAD	ALIM	ALIMD
1103026	Flentão	0,0066	NDur	NTRAD	ALIM	ALIMD
1103027	Quiabo	0,0048	NDur	NIHAD	ALIM	ALIMD
1103028	Tomate	0,2076	NDur	NIHAD	ALIM	ALIMD
1103043	Cebola	0,0954	NDur	NTRAD	ALIM	ALIMD
1103044	Cenoura	0,0426	NDur	NTRAD	ALIM	ALIMD
1103046	Mandioquinha (batata-baroa)	0,0088	NDur	NIHAD	ALIM	ALIMD
<b>1104</b>	<b>Açúcares e derivados</b>	<b>0,9628</b>	-	-	-	-
1104003	Açúcar refinado	0,1575	NDur	TRAD	ALIM	ALIMD
1104004	Açúcar cristal	0,4031	NDur	TRAD	ALIM	ALIMD
1104018	Balas	0,0176	NDur	IHAD	ALIM	ALIMD
1104023	Chocolate em barra e bombom	0,1371	NDur	IHAD	ALIM	ALIMD
1104032	Sorvete	0,1097	NDur	IHAD	ALIM	ALIMD
1104052	Chocolate e achocolatado em pó	0,1340	NDur	TRAD	ALIM	ALIMD
1104060	Doce de frutas em pasta	0,0039	NDur	IHAD	ALIM	ALIMD
<b>1105</b>	<b>Hortalças e verduras</b>	<b>0,1885</b>	-	-	-	-
1105001	Alface	0,0906	NDur	NTRAD	ALIM	ALIMD
1105004	Coentro	0,0090	NDur	NTRAD	ALIM	ALIMD
1105005	Couve	0,0171	NDur	NTRAD	ALIM	ALIMD
1105006	Couve-flor	0,0031	NDur	NIHAD	ALIM	ALIMD
1105010	Repolho	0,0240	NDur	NTRAD	ALIM	ALIMD
1105012	Cheiro-verde	0,0295	NDur	NIHAD	ALIM	ALIMD
1105019	Brocolis	0,0152	NDur	NIHAD	ALIM	ALIMD
<b>1106</b>	<b>Frutas</b>	<b>0,8085</b>	-	-	-	-
1106001	Banana-da-terra	0,0106	NDur	NTRAD	ALIM	ALIMD
1106003	Abacaxi	0,0275	NDur	NTRAD	ALIM	ALIMD
1106004	Abacate	0,0017	NDur	NIHAD	ALIM	ALIMD
1106005	Banana-d'água	0,0784	NDur	NTRAD	ALIM	ALIMD
1106006	Banana-maçã	0,0051	NDur	NTRAD	ALIM	ALIMD
1106008	Banana-prata	0,1562	NDur	NTRAD	ALIM	ALIMD
1106011	Laranja-baía	0,0071	NDur	NIHAD	ALIM	ALIMD
1106015	Limão	0,0019	NDur	NIHAD	ALIM	ALIMD
1106017	Maçã	0,1237	NDur	NTRAD	ALIM	ALIMD
1106018	Mamão	0,0865	NDur	NIHAD	ALIM	ALIMD
1106019	Manga	0,0098	NDur	NIHAD	ALIM	ALIMD
1106020	Maracujá	0,0057	NDur	NIHAD	ALIM	ALIMD
1106021	Melancia	0,0461	NDur	NTRAD	ALIM	ALIMD
1106023	Pera	0,0228	NDur	NTRAD	ALIM	ALIMD
1106027	Tangerina	0,0170	NDur	NTRAD	ALIM	ALIMD
1106028	Uva	0,0745	NDur	NTRAD	ALIM	ALIMD
1106039	Laranja-pera	0,1205	NDur	NTRAD	ALIM	ALIMD
1106051	Morango	0,0111	NDur	NTRAD	ALIM	ALIMD
1106084	Goiaba	0,0023	NDur	NTRAD	ALIM	ALIMD
<b>1107</b>	<b>Carnes</b>	<b>2,6692</b>	-	-	-	-
1107009	Fígado	0,0283	NDur	TRAD	ALIM	ALIMD
1107018	Carne de porco	0,2170	NDur	TRAD	ALIM	ALIMD
1107031	Carne de carneiro	0,0110	NDur	TRAD	ALIM	ALIMD
1107084	Contrafilé	0,3649	NDur	TRAD	ALIM	ALIMD
1107085	File-mignon	0,0595	NDur	TRAD	ALIM	ALIMD
1107087	Chã de dentro	0,2854	NDur	TRAD	ALIM	ALIMD
1107088	Alcatra	0,4485	NDur	TRAD	ALIM	ALIMD
1107089	Patinho	0,2083	NDur	TRAD	ALIM	ALIMD
1107090	Lagarto redondo	0,0186	NDur	TRAD	ALIM	ALIMD
1107091	Lagarto comum	0,0658	NDur	TRAD	ALIM	ALIMD
1107093	Músculo	0,1398	NDur	TRAD	ALIM	ALIMD
1107094	Pá	0,1189	NDur	TRAD	ALIM	ALIMD
1107095	Acém	0,2805	NDur	TRAD	ALIM	ALIMD
1107096	Peito	0,0330	NDur	TRAD	ALIM	ALIMD
1107099	Costela	0,3895	NDur	TRAD	ALIM	ALIMD
<b>1108</b>	<b>Pescados</b>	<b>0,2872</b>	-	-	-	-
1108002	Anchova	0,0040	NDur	NTRAD	ALIM	ALIMD
1108004	Corvina	0,0256	NDur	NTRAD	ALIM	ALIMD
1108005	Cavaliinha	0,0026	NDur	NTRAD	ALIM	ALIMD
1108006	Peixe	0,0499	NDur	NTRAD	ALIM	ALIMD
1108012	Sardinha	0,0123	NDur	NTRAD	ALIM	ALIMD
1108013	Camarão	0,0380	NDur	NTRAD	ALIM	ALIMD
1108015	Vermelho	0,0025	NDur	NTRAD	ALIM	ALIMD
1108019	Cavala	0,0054	NDur	NTRAD	ALIM	ALIMD
1108029	Cação	0,0069	NDur	NTRAD	ALIM	ALIMD
1108031	Merluza	0,0173	NDur	NTRAD	ALIM	ALIMD
1108032	Serra	0,0059	NDur	NTRAD	ALIM	ALIMD
1108038	Pescada	0,0605	NDur	NTRAD	ALIM	ALIMD
1108045	Caranguejo	0,0063	NDur	NTRAD	ALIM	ALIMD
1108049	Castanha	0,0013	NDur	NTRAD	ALIM	ALIMD
1108075	Salmão	0,0054	NDur	NTRAD	ALIM	ALIMD
1108080	Tilápia	0,0170	NDur	NTRAD	ALIM	ALIMD
1108083	Tucunaré	0,0046	NDur	NTRAD	ALIM	ALIMD
1108088	Dourada	0,0216	NDur	NTRAD	ALIM	ALIMD
<b>1109</b>	<b>Carnes e peixes industrializados</b>	<b>0,7511</b>	-	-	-	-
1109002	Presunto	0,1220	NDur	TRAD	ALIM	ALIMD

(continuação)

Código	Descrição	Peso	IPCA_Dur	IPCA_Trad	IPCA_Ind	IPCA_IndNovo
1109007	Salsicha	0,0976	NDur	TRAD	ALIM	ALIMD
1109008	Linguiça	0,2860	NDur	TRAD	ALIM	ALIMD
1109010	Mortadela	0,0917	NDur	TRAD	ALIM	ALIMD
1109012	Salame	0,0066	NDur	TRAD	ALIM	ALIMD
1109056	Carne-seca e de sol	0,1321	NDur	TRAD	ALIM	ALIMD
1109058	Carne de porco salgada e defumada	0,0131	NDur	TRAD	ALIM	ALIMD
1109088	Hambúrguer	0,0021	NDur	TRAD	ALIM	ALIMD
<b>1110</b>	<b>Aves e ovos</b>	<b>1,0637</b>	-	-	-	-
1110009	Frango inteiro	0,4652	NDur	TRAD	ALIM	ALIMD
1110010	Frango em pedaços	0,4118	NDur	TRAD	ALIM	ALIMD
1110044	Ovo de galinha	0,1867	NDur	NTRAD	ALIM	ALIMD
<b>1111</b>	<b>Leite e derivados</b>	<b>1,8964</b>	-	-	-	-
1111004	Leite longa vida	0,9489	NDur	TRAD	ALIM	ALIMD
1111008	Leite condensado	0,0144	NDur	TRAD	ALIM	ALIMD
1111009	Leite em pó	0,2090	NDur	TRAD	ALIM	ALIMD
1111011	Queijo	0,4899	NDur	TRAD	ALIM	ALIMD
1111012	Creme de leite	0,0023	NDur	TRAD	ALIM	ALIMD
1111019	Iogurte e bebidas lácteas	0,2119	NDur	TRAD	ALIM	ALIMD
1111031	Manteiga	0,0198	NDur	TRAD	ALIM	ALIMD
<b>1112</b>	<b>Panificados</b>	<b>1,7995</b>	-	-	-	-
1112003	Biscoito	0,4832	NDur	TRAD	ALIM	ALIMD
1112015	Pão francês	0,9888	NDur	TRAD	ALIM	ALIMD
1112017	Pão doce	0,0973	NDur	TRAD	ALIM	ALIMD
1112018	Pão de forma	0,1087	NDur	TRAD	ALIM	ALIMD
1112019	Bolo	0,1019	NDur	TRAD	ALIM	ALIMD
1112025	Pão de queijo	0,0196	NDur	TRAD	ALIM	ALIMD
<b>1113</b>	<b>Oleos e gorduras</b>	<b>0,4795</b>	-	-	-	-
1113013	Oleo de soja	0,3025	NDur	TRAD	ALIM	ALIMD
1113014	Azeite de oliva	0,0245	NDur	TRAD	ALIM	ALIMD
1113040	Margarina	0,1525	NDur	TRAD	ALIM	ALIMD
<b>1114</b>	<b>Bebidas e infusões</b>	<b>1,7639</b>	-	-	-	-
1114001	Suco de frutas	0,1628	NDur	TRAD	ALIM	ALIMD
1114004	Açaí (emulsão)	0,0357	NDur	TRAD	ALIM	ALIMD
1114022	Café moído	0,3672	NDur	TRAD	ALIM	ALIMD
1114023	Café solúvel	0,0147	NDur	TRAD	ALIM	ALIMD
1114029	Chá	0,0301	NDur	TRAD	ALIM	ALIMD
1114083	Refrigerante e água mineral	0,6814	NDur	TRAD	ALIM	ALIMD
1114084	Cerveja	0,3568	NDur	TRAD	ALIM	ALIMD
1114085	Outras bebidas alcoólicas	0,1152	NDur	TRAD	ALIM	ALIMD
<b>1115</b>	<b>Enlatados e conservas</b>	<b>0,1508</b>	-	-	-	-
1115004	Coco ralado	0,0069	NDur	TRAD	ALIM	ALIMD
1115006	Ervilha em conserva	0,0047	NDur	TRAD	ALIM	ALIMD
1115016	Palmito em conserva	0,0149	NDur	TRAD	ALIM	ALIMD
1115017	Pepino em conserva	0,0044	NDur	TRAD	ALIM	ALIMD
1115039	Sardinha em conserva	0,0373	NDur	TRAD	ALIM	ALIMD
1115050	Salsicha em conserva	0,0042	NDur	TRAD	ALIM	ALIMD
1115051	Carne em conserva	0,0058	NDur	TRAD	ALIM	ALIMD
1115053	Patê	0,0034	NDur	TRAD	ALIM	ALIMD
1115056	Sopa desidratada	0,0097	NDur	TRAD	ALIM	ALIMD
1115057	Azeitona	0,0249	NDur	TRAD	ALIM	ALIMD
1115058	Milho-verde em conserva	0,0189	NDur	TRAD	ALIM	ALIMD
1115075	Atum em conserva	0,0159	NDur	TRAD	ALIM	ALIMD
<b>1116</b>	<b>Sal e condimentos</b>	<b>0,3713</b>	-	-	-	-
1116001	Leite de coco	0,0040	NDur	TRAD	ALIM	ALIMD
1116005	Atomatado	0,1533	NDur	TRAD	ALIM	ALIMD
1116010	Alho	0,0704	NDur	TRAD	ALIM	ALIMD
1116013	Sal	0,0080	NDur	TRAD	ALIM	ALIMD
1116026	Fermento	0,0085	NDur	TRAD	ALIM	ALIMD
1116033	Maionese	0,0461	NDur	TRAD	ALIM	ALIMD
1116041	Vinagre	0,0048	NDur	TRAD	ALIM	ALIMD
1116048	Caldo concentrado	0,0271	NDur	TRAD	ALIM	ALIMD
1116071	Tempero misto	0,0492	NDur	TRAD	ALIM	ALIMD
<b>12</b>	<b>Alimentação fora do domicílio</b>	<b>7,9711</b>	-	-	-	-
<b>1201</b>	<b>Alimentação fora do domicílio</b>	<b>7,9711</b>	-	-	-	-
1201001	Refeição	4,7990	NDur	NTRAD	ALIM	ServN
1201003	Lanche	1,7481	NDur	NTRAD	ALIM	ServN
1201005	Café da manhã	0,0903	NDur	NTRAD	ALIM	ServN
1201007	Refrigerante e água mineral	0,3435	NDur	NTRAD	ALIM	ServN
1201009	Cafezinho	0,0652	NDur	NTRAD	ALIM	ServN
1201048	Cerveja	0,6086	NDur	NTRAD	ALIM	ServN
1201051	Outras bebidas alcoólicas	0,0636	NDur	NTRAD	ALIM	ServN
1201061	Doces	0,2528	NDur	NTRAD	ALIM	ServN
<b>2</b>	<b>Habitação</b>	<b>14,6169</b>	-	-	-	-
<b>21</b>	<b>Encargos e manutenção</b>	<b>9,9941</b>	-	-	-	-
<b>2101</b>	<b>Aluguel e taxas</b>	<b>6,7647</b>	-	-	-	-
2101001	Aluguel residencial	3,6971	Serv	NTRAD	Serv	ServN
2101002	Condomínio	1,5737	Serv	NTRAD	Serv	ServN
2101004	Taxa de água e esgoto	1,4794	ADurM	ADM	ADM	ADMIN
2101012	Mudança	0,0145	Serv	NTRAD	Serv	ServN
<b>2103</b>	<b>Reparos</b>	<b>2,4003</b>	-	-	-	-
2103005	Ferragens	0,0520	SDur	TRAD	IND	INDN
2103008	Material de eletricidade	0,0227	SDur	TRAD	IND	INDN
2103009	Material de pintura	0,0268	SDur	TRAD	IND	INDN
2103012	Vidro	0,0221	Dur	NTRAD	IND	INDN
2103014	Tinta	0,2206	SDur	TRAD	IND	INDN
2103032	Revestimento de piso e parede	0,1966	Dur	NTRAD	IND	INDN
2103039	Cimento	0,1867	Dur	NTRAD	IND	INDN
2103040	Tijolo	0,1496	Dur	NTRAD	IND	INDN
2103041	Material hidráulico	0,0574	Dur	TRAD	IND	INDN
2103042	Mão-de-obra	1,3358	Serv	NTRAD	Serv	ServN
2103048	Areia	0,0513	Dur	NTRAD	IND	INDN
2103055	Telha	0,0786	Dur	NTRAD	IND	INDN
<b>2104</b>	<b>Artigos de limpeza</b>	<b>0,8292</b>	-	-	-	-
2104005	Água sanitária	0,0558	NDur	TRAD	IND	INDN
2104008	Detergente	0,1245	NDur	TRAD	IND	INDN
2104009	Sabão em pó	0,3222	NDur	TRAD	IND	INDN
2104012	Desinfetante	0,0469	NDur	TRAD	IND	INDN
2104013	Inseticida	0,0057	NDur	TRAD	IND	INDN
2104015	Sabão em barra	0,0978	NDur	TRAD	IND	INDN
2104016	Esponja de limpeza	0,0534	NDur	TRAD	IND	INDN

(continuação)

Código	Descrição	Peso	IPCA_Dur	IPCA_Trad	IPCA_Ind	IPCA_IndNovo
2104032	Amaciante	0,1228	NDur	TRAD	IND	INDN
<b>22</b>	<b>Combustíveis e energia</b>	<b>4,6228</b>	-	-	-	-
<b>2201</b>	<b>Combustíveis (domésticos)</b>	<b>1,1930</b>	-	-	-	-
2201003	Carvão vegetal	0,0066	NDur	NTRAD	IND	INDN
2201004	Gás de botijão	1,1105	ADurM	ADM	ADM	ADMN
2201005	Gás encanado	0,0759	ADurM	ADM	ADM	ADMN
<b>2202</b>	<b>Energia elétrica residencial</b>	<b>3,4298</b>	-	-	-	-
2202003	Energia elétrica residencial	3,4298	ADurM	ADM	ADM	ADMN
<b>3</b>	<b>Artigos de residência</b>	<b>4,6758</b>	-	-	-	-
<b>31</b>	<b>Móveis e utensílios</b>	<b>2,3146</b>	-	-	-	-
<b>3101</b>	<b>Mobiliário</b>	<b>1,4532</b>	-	-	-	-
3101002	Móvel para sala	0,6006	Dur	TRAD	IND	INDN
3101003	Móvel para quarto	0,5047	Dur	TRAD	IND	INDN
3101015	Móvel para copa e cozinha	0,1989	Dur	TRAD	IND	INDN
3101016	Móvel infantil	0,0156	Dur	TRAD	IND	INDN
3101017	Colchão	0,1334	Dur	TRAD	IND	INDN
<b>3102</b>	<b>Utensílios e enfeites</b>	<b>0,5233</b>	-	-	-	-
3102005	Tapete	0,0783	Dur	TRAD	IND	INDN
3102006	Cortina	0,0869	Dur	TRAD	IND	INDN
3102007	Utensílios de metal	0,0923	SDur	TRAD	IND	INDN
3102009	Utensílios de vidro e louça	0,0630	SDur	TRAD	IND	INDN
3102010	Utensílios de plástico	0,0397	SDur	TRAD	IND	INDN
3102035	Flores naturais	0,0231	NDur	TRAD	IND	INDN
3102040	Utensílios diversos	0,1400	NDur	TRAD	IND	INDN
<b>3103</b>	<b>Camã, mesa e banho</b>	<b>0,3382</b>	-	-	-	-
3103001	Roupa de cama	0,2560	SDur	TRAD	IND	INDN
3103003	Roupa de banho	0,0822	SDur	TRAD	IND	INDN
<b>32</b>	<b>Aparelhos eletroeletrônicos</b>	<b>2,0075</b>	-	-	-	-
<b>3201</b>	<b>B eletrodomésticos e equipamentos</b>	<b>1,0914</b>	-	-	-	-
3201001	Refrigerador	0,4972	Dur	TRAD	IND	INDN
3201002	Ar-condicionado	0,0363	Dur	TRAD	IND	INDN
3201006	Máquina de lavar roupa	0,2415	Dur	TRAD	IND	INDN
3201012	Liquidificador	0,0034	Dur	TRAD	IND	INDN
3201013	Ventilador	0,0244	Dur	TRAD	IND	INDN
3201021	Fogão	0,2115	Dur	TRAD	IND	INDN
3201050	Chuveiro elétrico	0,0237	Dur	TRAD	IND	INDN
3201065	Forno de micro-ondas	0,0533	Dur	TRAD	IND	INDN
<b>3202</b>	<b>Tv, som e informática</b>	<b>0,9161</b>	-	-	-	-
3202001	Televisor	0,3065	Dur	TRAD	IND	INDN
3202003	Aparelho de som	0,0908	Dur	TRAD	IND	INDN
3202005	Aparelho de DVD	0,0906	Dur	TRAD	IND	INDN
3202013	Antena	0,0102	Dur	TRAD	IND	INDN
3202028	Microcomputador	0,4181	Dur	TRAD	IND	INDN
<b>33</b>	<b>Consertos e manutenção</b>	<b>0,3536</b>	-	-	-	-
<b>3301</b>	<b>Consertos e manutenção</b>	<b>0,3536</b>	-	-	-	-
3301002	Conserto de refrigerador	0,0780	Serv	NTRAD	Serv	ServN
3301006	Conserto de televisor	0,0908	Serv	NTRAD	Serv	ServN
3301009	Conserto de aparelho de som	0,0057	Serv	NTRAD	Serv	ServN
3301015	Conserto de máquina de lavar roupa	0,0600	Serv	NTRAD	Serv	ServN
3301022	Reforma de estofado	0,1192	Serv	NTRAD	Serv	ServN
<b>4</b>	<b>Vestuário</b>	<b>6,6692</b>	-	-	-	-
<b>41</b>	<b>Roupas</b>	<b>4,3243</b>	-	-	-	-
<b>4101</b>	<b>Roupa masculina</b>	<b>1,5957</b>	-	-	-	-
4101002	Calça comprida masculina	0,4829	SDur	TRAD	IND	INDN
4101004	Terno	0,0662	SDur	TRAD	IND	INDN
4101005	Agasalho masculino	0,0940	SDur	TRAD	IND	INDN
4101006	Short e bermuda masculina	0,2415	SDur	TRAD	IND	INDN
4101008	Cueca	0,0269	SDur	TRAD	IND	INDN
4101009	Camisa/camiseta masculina	0,6842	SDur	TRAD	IND	INDN
<b>4102</b>	<b>Roupa feminina</b>	<b>1,9922</b>	-	-	-	-
4102002	Calça comprida feminina	0,5205	SDur	TRAD	IND	INDN
4102003	Agasalho feminino	0,0826	SDur	TRAD	IND	INDN
4102004	Saia	0,0251	SDur	TRAD	IND	INDN
4102005	Vestido	0,3478	SDur	TRAD	IND	INDN
4102008	Blusa	0,7600	SDur	TRAD	IND	INDN
4102010	Lingerie	0,1635	SDur	TRAD	IND	INDN
4102013	Bermuda e short feminino	0,0927	SDur	TRAD	IND	INDN
<b>4103</b>	<b>Roupa infantil</b>	<b>0,7364</b>	-	-	-	-
4103001	Uniforme escolar	0,0252	SDur	TRAD	IND	INDN
4103002	Calça comprida infantil	0,1360	SDur	TRAD	IND	INDN
4103005	Agasalho infantil	0,0438	SDur	TRAD	IND	INDN
4103007	Vestido infantil	0,0797	SDur	TRAD	IND	INDN
4103008	Bermuda e short infantil	0,1156	SDur	TRAD	IND	INDN
4103011	Camisa/camiseta infantil	0,2877	SDur	TRAD	IND	INDN
4103031	Conjunto infantil	0,0486	SDur	TRAD	IND	INDN
<b>42</b>	<b>Calçados e acessórios</b>	<b>1,9213</b>	-	-	-	-
<b>4201</b>	<b>Calçados e acessórios</b>	<b>1,9213</b>	-	-	-	-
4201002	Sapato masculino	0,2095	SDur	TRAD	IND	INDN
4201003	Sapato feminino	0,3505	SDur	TRAD	IND	INDN
4201004	Sapato infantil	0,0135	SDur	TRAD	IND	INDN
4201006	Sandália/chinelo masculino	0,0234	SDur	TRAD	IND	INDN
4201007	Sandália/chinelo feminino	0,3907	SDur	TRAD	IND	INDN
4201008	Sandália/chinelo infantil	0,0324	SDur	TRAD	IND	INDN
4201015	Bolsa	0,2049	SDur	TRAD	IND	INDN
4201063	Tênis	0,6963	SDur	TRAD	IND	INDN
<b>43</b>	<b>Joias e bijuterias</b>	<b>0,3362</b>	-	-	-	-
<b>4301</b>	<b>Joias e bijuterias</b>	<b>0,3362</b>	-	-	-	-
4301001	Bijuteria	0,1651	Dur	TRAD	IND	INDN
4301002	Joia	0,1562	Dur	TRAD	IND	INDN
4301004	Relógio de pulso	0,0149	Dur	TRAD	IND	INDN
<b>44</b>	<b>Tecidos e armarinho</b>	<b>0,0873</b>	-	-	-	-
<b>4401</b>	<b>Tecidos e armarinho</b>	<b>0,0873</b>	-	-	-	-
4401001	Tecido	0,0536	SDur	TRAD	IND	INDN
4401002	Artigos de armarinho	0,0167	SDur	TRAD	IND	INDN
4401005	Acortinado (mosquiteiro)	0,0170	SDur	TRAD	IND	INDN
<b>5</b>	<b>Transportes</b>	<b>20,5421</b>	-	-	-	-
<b>51</b>	<b>Transportes</b>	<b>20,5421</b>	-	-	-	-
<b>5101</b>	<b>Transporte público</b>	<b>4,8745</b>	-	-	-	-
5101001	Onibus urbano	2,7074	ADurM	ADM	ADM	ADMN
5101002	Táxi	0,3914	ADurM	ADM	ADM	ADMN
5101004	Trem	0,0629	ADurM	ADM	ADM	ADMN

(continuação)

Código	Descrição	Peso	IP CA_Dur	IP CA_Trad	IP CA_Ind	IP CA_IndNovo
5101006	Onibus intermunicipal	0,7188	ADurM	ADM	ADM	ADMN
5101007	Onibus interestadual	0,2531	ADurM	ADM	ADM	ADMN
5101010	Passagem aérea	0,5669	ADurM	ADM	ADM	ServN
5101011	Metró	0,0733	ADurM	ADM	ADM	ADMN
5101022	Transporte hidroviário	0,0076	ADurM	ADM	ADM	ADMN
5101026	Transporte escolar	0,0931	Serv	NTRAD	Serv	ServN
<b>5102</b>	<b>Veículo próprio</b>	<b>10,3167</b>	-	-	-	-
5102001	Automóvel novo	3,6073	Dur	TRAD	IND	INDN
5102004	Emplacamento e licença	1,0828	ADurM	ADM	ADM	ADMN
5102005	Seguro voluntário de veículo	0,3289	Serv	NTRAD	Serv	ServN
5102006	Multa	0,0400	ADurM	ADM	ADM	ADMN
5102007	Óleo lubrificante	0,1095	ADurM	ADM	ADM	INDN
5102009	Acessórios e peças	0,3980	SDur	TRAD	IND	INDN
5102010	Pneu	0,2335	SDur	TRAD	IND	INDN
5102011	Conserto de automóvel	1,6952	Serv	NTRAD	Serv	ServN
5102013	Estacionamento	0,1011	Serv	NTRAD	Serv	ServN
5102015	Pedágio	0,1225	ADurM	ADM	ADM	ADMN
5102019	Lubrificação e lavagem	0,0407	Serv	NTRAD	Serv	ServN
5102020	Automóvel usado	1,7235	Dur	NTRAD	IND	INDN
5102037	Pintura de veículo	0,0509	Serv	NTRAD	Serv	ServN
5102051	Aluguel de veículo	0,0077	Serv	NTRAD	Serv	ServN
5102053	Motocicleta	0,7751	Dur	TRAD	IND	INDN
<b>5104</b>	<b>Combustíveis (veículos)</b>	<b>5,3510</b>	-	-	-	-
5104001	Gasolina	4,1106	ADurM	ADM	ADM	ADMN
5104002	Etanol	1,0018	NDur	TRAD	IND	ADMN
5104003	Óleo diesel	0,1250	ADurM	ADM	ADM	ADMN
5104005	Gás veicular	0,1137	ADurM	ADM	ADM	ADMN
<b>6</b>	<b>Saúde e cuidados pessoais</b>	<b>11,0936</b>	-	-	-	-
<b>61</b>	<b>Produtos farmacêuticos e óticos</b>	<b>3,7694</b>	-	-	-	-
<b>6101</b>	<b>Produtos farmacêuticos</b>	<b>3,4733</b>	-	-	-	-
6101001	Anti-infeccioso e antibiótico	0,2316	ADurM	NTRAD	ADM	ADMN
6101002	Analgésico e antitérmico	0,4122	ADurM	NTRAD	ADM	ADMN
6101003	Anti-inflamatório e antirreumático	0,3224	ADurM	NTRAD	ADM	ADMN
6101004	Antigripal e antitussígeno	0,1990	ADurM	NTRAD	ADM	ADMN
6101006	Dermatológico	0,1127	ADurM	NTRAD	ADM	ADMN
6101007	Antialérgico e broncodilatador	0,1880	ADurM	NTRAD	ADM	ADMN
6101009	Gastroprotetor	0,2011	ADurM	NTRAD	ADM	ADMN
6101010	Vitamina e fortificante	0,2107	ADurM	NTRAD	ADM	ADMN
6101011	Hormônio	0,4189	ADurM	NTRAD	ADM	ADMN
6101013	Psicotrópico e anorexígeno	0,3851	ADurM	NTRAD	ADM	ADMN
6101014	Hipotensor e hipocolesterolêmico	0,7058	ADurM	NTRAD	ADM	ADMN
6101051	Oftalmológico	0,0859	ADurM	NTRAD	ADM	ADMN
<b>6102</b>	<b>Produtos óticos</b>	<b>0,2962</b>	-	-	-	-
6102002	Armação de óculos	0,0501	Dur	TRAD	IND	INDN
6102003	Óculos sem grau	0,1041	Dur	TRAD	IND	INDN
6102011	Lentes de óculos e de contato	0,1419	Dur	TRAD	IND	INDN
<b>62</b>	<b>Serviços de saúde</b>	<b>4,6563</b>	-	-	-	-
<b>6201</b>	<b>Serviços médicos e dentários</b>	<b>1,0354</b>	-	-	-	-
6201002	Médico	0,4140	Serv	NTRAD	Serv	ServN
6201003	Dentista	0,4354	Serv	NTRAD	Serv	ServN
6201005	Aparelho ortodôntico	0,0528	SDur	NTRAD	IND	INDN
6201006	Artigos ortopédicos	0,0038	SDur	NTRAD	IND	INDN
6201007	Fisioterapeuta	0,0529	Serv	NTRAD	Serv	ServN
6201010	Psicólogo	0,0764	Serv	NTRAD	Serv	ServN
<b>6202</b>	<b>Serviços laboratoriais e hospitalares</b>	<b>0,5729</b>	-	<b>NTRAD</b>	-	-
6202003	Exame de laboratório	0,1135	Serv	NTRAD	Serv	ServN
6202004	Hospitalização e cirurgia	0,3588	Serv	NTRAD	Serv	ServN
6202006	Exame de imagem	0,1006	Serv	NTRAD	Serv	ServN
<b>6203</b>	<b>Plano de saúde</b>	<b>3,0480</b>	-	<b>NTRAD</b>	-	-
6203001	Plano de saúde	3,0480	ADurM	ADM	ADM	ADMN
<b>63</b>	<b>Cuidados pessoais</b>	<b>2,6678</b>	-	-	-	-
<b>6301</b>	<b>Higiene pessoal</b>	<b>2,6678</b>	-	-	-	-
6301001	Produto para cabelo	0,2748	NDur	TRAD	IND	INDN
6301002	Fralda descartável	0,0588	NDur	TRAD	IND	INDN
6301004	Produto para barba	0,0113	NDur	TRAD	IND	INDN
6301006	Produto para pele	0,3865	NDur	TRAD	IND	INDN
6301007	Produto para higiene bucal	0,1828	NDur	TRAD	IND	INDN
6301010	Produto para unha	0,0963	NDur	TRAD	IND	INDN
6301011	Perfume	1,0443	NDur	TRAD	IND	INDN
6301014	Desodorante	0,0945	NDur	TRAD	IND	INDN
6301015	Absorvente higiênico	0,0107	NDur	TRAD	IND	INDN
6301016	Sabonete	0,1612	NDur	TRAD	IND	INDN
6301017	Papel higiênico	0,2075	NDur	TRAD	IND	INDN
6301020	Artigos de maquiagem	0,1391	NDur	TRAD	IND	INDN
<b>7</b>	<b>Despesas pessoais</b>	<b>9,9421</b>	-	-	-	-
<b>71</b>	<b>Serviços pessoais</b>	<b>6,0109</b>	-	-	-	-
<b>7101</b>	<b>Serviços pessoais</b>	<b>6,0109</b>	-	-	-	-
7101001	Costureira	0,0482	Serv	NTRAD	Serv	ServN
7101005	Manicure	0,3994	Serv	NTRAD	Serv	ServN
7101009	Cabeleireiro	1,2449	Serv	NTRAD	Serv	ServN
7101010	Empregado doméstico	3,5149	Serv	NTRAD	Serv	ServN
7101014	Depilação	0,0103	Serv	NTRAD	Serv	ServN
7101036	Despachante	0,0851	Serv	NTRAD	Serv	ServN
7101076	Serviço bancário	0,6958	Serv	NTRAD	Serv	ServN
7101090	Conselho de classe	0,0122	Serv	NTRAD	Serv	ServN
<b>72</b>	<b>Recreação, fumo e fotografia</b>	<b>3,9311</b>	-	-	-	-
<b>7201</b>	<b>Recreação</b>	<b>3,0659</b>	-	-	-	-
7201001	Cinema	0,1830	Serv	NTRAD	Serv	ServN
7201002	CD e DVD	0,0648	SDur	TRAD	IND	INDN
7201003	Ingresso para jogo	0,0151	Serv	NTRAD	Serv	ServN
7201006	Clube	0,1535	Serv	NTRAD	Serv	ServN
7201010	Instrumento musical	0,0415	Dur	TRAD	IND	INDN
7201018	Tratamento de animais	0,1898	Serv	NTRAD	Serv	ServN
7201019	Bicicleta	0,0953	Dur	TRAD	IND	INDN
7201020	Alimento para animais	0,2495	NDur	TRAD	IND	INDN
7201023	Brinquedo	0,4481	SDur	TRAD	IND	INDN
7201052	Locação de DVD	0,1390	Serv	NTRAD	Serv	ServN
7201054	Boate e danceteria	0,2843	Serv	NTRAD	Serv	ServN
7201063	Jogos de azar	0,4146	ADurM	ADM	ADM	ADMN
7201068	Motel	0,0040	Serv	NTRAD	Serv	ServN
7201090	Hotel	0,3842	Serv	NTRAD	Serv	ServN
7201095	Excursão	0,3990	Serv	NTRAD	Serv	ServN

(continuação)

Código	Descrição	Peso	IPCA_Dur	IPCA_Trad	IPCA_Ind	IPCA_IndNovo
<b>7202</b>	<b>Fumo</b>	<b>0,7806</b>	-	<b>NTRAD</b>	-	-
7202041	Cigarro	0,7806	NDur	TRAD	IND	INDN
<b>7203</b>	<b>Fotografia e filmagem</b>	<b>0,0847</b>	-	<b>NTRAD</b>	-	-
7203001	Máquina fotográfica	0,0608	Dur	TRAD	IND	INDN
7203003	Revelação e cópia	0,0238	Serv	NTRAD	Serv	ServN
<b>8</b>	<b>Educação</b>	<b>4,3735</b>	-	-	-	-
<b>81</b>	<b>Cursos, leitura e papelaria</b>	<b>4,3735</b>	-	-	-	-
<b>8101</b>	<b>Cursos regulares</b>	<b>2,7530</b>	-	-	-	-
8101001	Creche	0,0150	Serv	NTRAD	Serv	ServN
8101002	Educação infantil	0,1673	Serv	NTRAD	Serv	ServN
8101003	Ensino fundamental	0,6499	Serv	NTRAD	Serv	ServN
8101004	Ensino médio	0,3100	Serv	NTRAD	Serv	ServN
8101005	Ensino superior	1,3869	Serv	NTRAD	Serv	ServN
8101006	Pós-graduação	0,2239	Serv	NTRAD	Serv	ServN
<b>8102</b>	<b>Leitura</b>	<b>0,5619</b>	-	-	-	-
8102001	Jornal diário	0,1441	NDur	NTRAD	IND	INDN
8102002	Assinatura de jornal	0,0397	NDur	NTRAD	IND	INDN
8102004	Revista	0,2225	NDur	NTRAD	IND	INDN
8102005	Livro	0,1556	NDur	NTRAD	IND	INDN
<b>8103</b>	<b>Papelaria</b>	<b>0,3268</b>	-	-	-	-
8103001	Caderno	0,1298	NDur	TRAD	IND	INDN
8103002	Fotocópia	0,0264	Serv	NTRAD	Serv	ServN
8103014	Artigos de papelaria	0,1707	SDur	TRAD	IND	INDN
<b>8104</b>	<b>Cursos diversos</b>	<b>0,7318</b>	-	-	-	-
8104001	Curso preparatório	0,1446	Serv	NTRAD	Serv	ServN
8104002	Curso técnico	0,0725	Serv	NTRAD	Serv	ServN
8104003	Curso de idioma	0,2170	Serv	NTRAD	Serv	ServN
8104004	Curso de informática	0,0873	Serv	NTRAD	Serv	ServN
8104006	Atividades físicas	0,2103	Serv	NTRAD	Serv	ServN
<b>9</b>	<b>Comunicação</b>	<b>4,9631</b>	-	-	-	-
<b>91</b>	<b>Comunicação</b>	<b>4,9631</b>	-	-	-	-
<b>9101</b>	<b>Comunicação</b>	<b>4,9631</b>	-	-	-	-
9101001	Correio	0,0106	ADurM	ADM	ADM	ADMN
9101002	Telefone fixo	1,5368	ADurM	ADM	ADM	ADMN
9101003	Telefone público	0,1181	ADurM	ADM	ADM	ADMN
9101008	Telefone celular	1,5209	ADurM	ADM	ADM	ServN
9101018	Acesso à internet	0,3177	Serv	NTRAD	Serv	ServN
9101019	Aparelho telefônico	0,2607	Dur	TRAD	IND	INDN
9101021	Telefone com internet	0,8390	Serv	NTRAD	Serv	ServN
9101022	Tv por assinatura com internet	0,3593	Serv	NTRAD	Serv	ServN

Fonte: IBGE

Nota: NDur = Não Duráveis; Dur = Duráveis; SDur = Semi Duráveis; ADM = Administrados; ADMN = Administrados Novo; Serv = Serviços; ServN = Serviços Novo; IND = Industrializados; INDN = Industrializados Novo; TRAD = Comercializáveis; NTRAD = Não Comercializáveis; ALIM

### Anexo III –Compatibilização das estruturas de itens do IPCA

<b>Código</b>	<b>Item</b>	<b>Jan/1991 a Jul/1999</b>	<b>Ago/1999 a Jun/2006</b>	<b>A partir de Jul/2006</b>
3301	Consertos e manutenção	n.d.	Item 3301 Consertos e manutenção	Item 3301 Consertos e manutenção
6203	Plano de Saúde	n.d.	Item 6203 Plano de Saúde	Item 6203 Plano de Saúde
7203	Fotografia e imagem	Agregação dos subitens 7201011 máquina fotografica e 7201011 Acessórios para fotografia	Item 7203 Fotografia e Imagem	Item 7203 Fotografia e Imagem
7201	Recreação	Retirada dos subitens 7201011 máquina fotografica e 7201011 Acessórios para fotografia do item recreação	Item 7201 Recreação	Item 7201 Recreação
8101	Cursos	Agregação dos subitens do item educação: 7301004.Livros didáticos; 7301006.Cursos formais; 7301020.Livros e revistas técnicas; 7301021.Creche	Retirada do subitem 8101014. cursos diversos no item cursos 8101.	Item 8101 Cursos
8104	Cursos diversos	Considera o subitem 7301007.Cursos diversos	Considera o subitem 8101014.Cursos diversos	Item 8104 Cursos Diversos
8103	Papelaria	Agregação dos subitens do item educação: 7301002.Cadernos; 7301003.Artigo de papelaria	Item 8103 Papelaria	Item 8103 Papelaria
9101	Comunicação	Considera o item 5201 Comunicações	Considera o item 9101.Comunicação	Considera o item 9101.Comunicação

Fonte: Elaboração do autor


**Anexo IV – Resultados Modelos Markov-Switching e Estrutural para o último mês da amostra (março 2012)**

***Modelo Markov-Switching***

	<b>Coeficiente</b>	
D1	0.0731	(0.0739)
D2	-0.0964	(0.072)
D3	-0.1008	(0.0701)
D4	-0.0042	(0.0701)
D5	-0.1852	(0.0723)
D6	-0.2888	(0.088)
D7	-0.1132	(0.0812)
D8	-0.2621	(0.072)
D9	-0.1642	(0.0783)
D10	-0.0253	(0.0745)
D11	-0.0576	(0.0688)
c regime(1)	0.1738	(0.0312)
c regime(2)	0.6016	(0.2164)
IPCA(-1) regime(1)	0.5406	(0.0618)
IPCA(-1) regime(2)	0.4818	(0.1648)
$\varepsilon$ regime(1)	0.1833	(0.0167)
$\varepsilon$ regime(2)	0.5156	(0.0798)
Prob {1 1}	0.9391	(0.0396)
Prob {1 2}	0.3218	(0.1628)

Fonte: Elaboração do autor






### Modelo Estrutural em Espaço-estado

	<b>Coefficiente</b>	<b>p-valor</b>
Nível	3409.9188	[0.00000]
Inclinação	10.45802	[0.00487]
Sazonalidade	37.80053	[0.00008]
Ciclo	3.23397	[.NaN]
Efeitos sazonais:		
Período	Coefficiente	p-valor
1	2.2046	[0.37114]
2	4.86551	[0.04891]
3	5.09254	[0.03969]
4	6.69027	[0.00695]
5	5.26303	[0.03306]
6	0.32428	[0.89524]
7	0.2924	[0.90592]
8	-3.05766	[0.21845]
9	-6.62902	[0.00801]
10	-6.38048	[0.01036]
11	-5.59917	[0.02367]
12	-3.06629	[0.21283]

Fonte: Elaboração do autor



## REFERÊNCIAS BIBLIOGRÁFICAS

AKAIKE, H. (1973). Information theory and an extension of the likelihood principle. In B. Petrov and F. Czaki (Eds.), *Second International Symposium on Information Theory*, pp. 267-287. Budapest: Akademia Kiado.

AREOSA, W. D.; MEDEIROS, M. Inflation dynamics in Brazil: the case of a small open economy. *Brazilian Review of Econometrics*, v. 27(1), May, p. 131-166, 2007.

ARRUDA, E. F.; FERREIRA, R. T.; CASTELAR, Ivan. Modelos lineares e não lineares da curva de Phillips para previsão da taxa de inflação no Brasil. *Rev. Bras. Econ.* [online]. 2011, vol.65, n.3, pp. 237-252. ISSN 0034-7140. <http://dx.doi.org/10.1590/S0034-71402011000300001>.

BENALAL, N.; DIAZ DEL HOYO, J. L.; LANDAU, B.; ROMA, M.; SKUDELNY, F. (2004). To aggregate or not to aggregate? Euro area inflation forecasting, Working Paper 374, European Central Bank.

BERNANKE, B. (2007). Inflation expectations and inflation forecasting, Speech at the Monetary Economics Workshop of the NBER Summer Institute.

BERNANKE, B.; BOIVIN, J.; ELIASZ, P. (2005). Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach. *Quarterly Journal of Economics* 120, 387-422.

BIDARKOTA, P. V. (2001). Alternative regime switching models for forecasting inflation. *J. Forecast.*, 20: 21-35. doi: 10.1002/1099-131X(200101)20:1<21::AID-FOR763>3.0.CO;2-0

BIDARKOTA, P. V.; MCCULLOCH, J. H. (1998), Optimal univariate inflation forecasting with symmetric stable shocks. *J. Appl. Econ.*, 13: 659-670. doi: 10.1002/(SICI)1099-1255(199811/12)13:6<659::AID-JAE481>3.0.CO;2-Q

BOGDANSKI, J.; TOMBINI, A. A.; WERLANG, S. R. C. Implementing inflation targeting in Brazil. *Money Affairs / Cemla, Centre for Latin American Monetary Studies*, v. 14, n. 1, p. 1-23, 2001.

BOX, G. E. P.; JENKINS, G. M. (1976). *Time Series Analysis: Forecasting and Control* (2nd ed.). San Francisco, CA: Holden-Day.

BRUNEAU, C.; DE BANDT, O.; FLAGEOLLET, A.; MICHAUX, E. (2007). Forecasting inflation using economic indicators: The case of France. *Journal of Forecasting* 26: 1-22.

CASTLE, J.L.; HENDRY, D.F. (2007). Forecasting UK inflation: the roles of structural breaks and time disaggregation. Discussion Paper No.309, Department of Economics, University of Oxford.

CASTLE, J.L.; HENDRY, D.F.; CLEMENTS, M. P. (2011). Forecasting by Factors, by Variables, by Both, or Neither? Working paper, Economics Department, University of Oxford, 2011.

DIEBOLD, F. X.; MARIANO, R. S. (1995). Comparing Predictive Accuracy. *Journal of Business and Economic Statistics*, 13, 253–263.

DOORNIK, J. A.; HENDRY, D. F. (2007). Empirical Econometric Modelling: PcGive 12 Volume I. London: Timberlake Consultants Press.

DUARTE, C.; RUA, A. (2007). Forecasting inflation through a bottom-up approach: how bottom is bottom? *Economic Modelling*, 24, 941-953.

DURBIN, J.; KOOPMAN, S. J. Time series analysis by state space methods. Oxford: Oxford University, 2004.

ENGLE, R. F.; BROWN, S. J.; Model selection for forecasting. *Applied Mathematics and Computation*, Volume 20, Issues 3–4, November 1986, Pages 313-327, ISSN 0096-3003, 10.1016/0096-3003(86)90009-3.

EVANS M., WACHTEL, P. 1993. Inflation regimes and the sources of inflation uncertainty. *Journal of Money, Credit and Banking* 25: No. 3, 475 – 520.

GOMEZ, V.; MARAVALL, A. (2001). Automatic modeling methods for univariate series. In D. Pena, G. C. Tiao, and R. S. Tsay (Eds.), *A Course in Time Series Analysis*. New York, NY: J. Wiley and Sons.

GRANGER, C. W. J.; ANDERSON, A. P. (1978). Introduction to Bilinear Time Series Models. Vandenhoeck and Ruprecht.

HANSEN, P. R. (2005). A Test for Superior Predictive Ability. *Journal of Business and Economic Statistics*, 23, 365–380.

HARVEY, D. I.; LEYBOURNE, S. J.; NEWBOLD, P. (1997). Testing the Equality of Prediction Mean Squared Errors. *International Journal of Forecasting*, 13, 281–291.

HENDRY, D.F.; HUBRICH, K. (2010). Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate. Working Paper Series1155, European Central Bank.

HENDRY, David F.; HUBRICH, Kirstin. Forecasting Economic Aggregates by Disaggregates (January 2006). CEPR Discussion Paper No. 5485. Available at SSRN: <http://ssrn.com/abstract=900409>

HUBRICH, K. (2005). Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting* 21(1): 119–136.

INOUE, A.; KILIAN, L. (2006). On the selection of forecasting models. *Journal of Econometrics*, 130, 273–306.

KIM, C-J. 1993. Unobserved-component time series models with Markov switching heteroskedasticity: Changes in regime and the link between inflation rates and inflation uncertainty. *Journal of Business & Economic Statistics* 11: No. 3, 341-349.

KOHN, R. (1982). When is an aggregate of a time series efficiently forecast by its past? *Journal of Econometrics* (18): 337–349.

LÜTKEPOHL, H., 1984a. Forecasting contemporaneously aggregated vector ARMA processes. *Journal of Business and Economic Statistics* 2 (3), 201–214.

MEHRA, R.K. 1974. Identification in control and econometrics: Similarities and differences. *Annals of Economic and Social Measurement*, Volume 3, number 1 (1974), Sanford V. Berg, editor (p. 21 - 48)

MOSER, G.; RUMLER, F.; SCHARLER, J. (2007). Forecasting Austrian inflation. *Economic Modelling*. forthcoming.

NIJMAN, T. E.; PALM, F. C. (1990). Predictive accuracy gain from disaggregate sampling in ARIMA models. *Journal of Business & Economic Statistics* 8: 405–415.

PALM, F. C.; NIJMAN, T. E. (1984). Missing Observations in the Dynamic Regression Model. *Econometrica*, 52, 1415-1435.

PALM, F. C.; NIJMAN, T. E. (1984). Missing observations in the dynamic regression model. *Econometrica* 52, 1415–36.

REIJER, A.; VLAAR, P. (2006). Forecasting inflation: An art as well as a science! *De Economist* 127(1): 19–40.

ROSE, E. (1977). Forecasting aggregates of independent ARIMA processes. *Journal of Econometrics* 5: 323-345.

SACHSIDA, A.; MENDONÇA, M. J. Reexaminando a Curva de Phillips brasileira com dados de seis regiões metropolitanas. Ipea, Texto para Discussão, 2009.

SACHSIDA, A.; RIBEIRO, M.; DOS SANTOS, C. H. Curva de Phillips e a experiência brasileira. Ipea, Texto para Discussão 1429, 2009

SCHWARTZMAN, F. F. Estimativa de Curva de Phillips para o Brasil com preços desagregados. *Economia Aplicada*, v. 10(1), jan. – mar., p. 137-155, 2006.

SORENSEN, H. W.; ALSPACH, D. L. (1971). Recursive Bayesian estimation using Gaussian sum. *Automatica*, 7, 465-79.

STOCK, J. H.; WATSON, M. W. (1998). Diffusion indexes. Working Paper 6702, NBER.

STOCK, J. H.; WATSON, M. W. (2002). Macroeconomic forecasting using diffusion indices. *Journal of Business and Economic Statistics* 20(2): 147–162.

STOCK, J. H.; WATSON, M.W. (1999). Forecasting inflation. *Journal of Monetary Economics* 44: 293–335.

TIAO, G.; GUTTMAN, A. (1980). Forecasting contemporaneous aggregates of multiple time series. *Journal of Econometrics* 12: 219-230.

WHITE, H. (2000). A Reality Check for Data Snooping. *Econometrica*, 68, 1097–1126.