

FUNDAÇÃO GETULIO VARGAS  
ESCOLA DE ECONOMIA DE SÃO PAULO

RAFAEL KEITI OISKI GRUNHO DE SOUZA

**DESAGREGAÇÃO E PESOS ESTOCÁSTICOS EM PROJEÇÕES DE  
AGREGADOS ECONÔMICOS: UMA ANÁLISE PARA O PIB BRASILEIRO**

SÃO PAULO

2015

RAFAEL KEITI OISKI GRUNHO DE SOUZA

**DESAGREGAÇÃO E PESOS ESTOCÁSTICOS EM PROJEÇÕES DE  
AGREGADOS ECONÔMICOS: UMA ANÁLISE PARA O PIB BRASILEIRO**

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

Campo de conhecimento: Economia

Orientador: Prof. Dr. Emerson Fernandes  
Marçal

SÃO PAULO

2015

Souza, Rafael Keiti Oiski Grunho de.

Desagregação e pesos estocásticos em projeções de agregados econômicos: uma análise para o PIB brasileiro / Rafael Keiti Oiski Grunho de Souza. - 2015.  
60 f.

Orientador: Emerson Fernandes Marçal

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

1. Produto interno bruto - Brasil. 2. Modelos econométricos. 3. Algoritmos.  
I. Marçal, Emerson Fernandes. II. Dissertação (MPFE) - Escola de Economia de São Paulo. III. Título.

CDU 330.55(81)

RAFAEL KEITI OISKI GRUNHO DE SOUZA

**DESAGREGAÇÃO E PESOS ESTOCÁSTICOS EM PROJEÇÕES DE  
AGREGADOS ECONÔMICOS: UMA ANÁLISE PARA O PIB BRASILEIRO**

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 de aprovação:**

03/02/2015

**Banca examinadora:**

---

Prof. Dr. Emerson Fernandes Marçal  
(Orientador)  
FGV-EESP

---

Prof. Dr. Rogério Mori  
FGV-EESP

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Marislei Nishijima  
USP-EACH

## **AGRADECIMENTOS**

À mim mesmo, pelo empenho e suporte financeiro. À minha família, por me aguentar. Ao Professor Emerson Marçal, pela orientação e paciência. Aos Professores Marislei Nishijima e Rogério Mori, pela participação na banca e observações.

## RESUMO

O presente estudo tem como objetivo comparar e combinar diferentes técnicas de projeção para o PIB trimestral brasileiro de 1991 ao segundo trimestre de 2014, utilizando dados agregados, e dados desagregados com pesos fixos e estocásticos. Os modelos desagregados univariados e multivariados, assim como os pesos estocásticos, foram estimados pelo algoritmo *Autometrics* criado por Doornik (2009), através dos níveis de desagregação disponibilizados pelo IBGE no Sistema de Contas Nacionais. Os modelos agregados foram estimados pelo *Autometrics*, por *Markov-Switching* e por modelos estruturais de espaço-estado. A metodologia de comparação de projeções utilizada foi o *Model Confidence Set*, desenvolvida por Hanse, Lunde e Nason (2011). Foram realizadas duas simulações, sendo a primeira com a análise fora da amostra a partir de 2008, e a segunda a partir de 2000, com horizonte de projeção de até 6 passos à frente. Os resultados sugerem que os modelos desagregados com pesos fixos desempenham melhor nos dois primeiros passos, enquanto nos períodos restantes os modelos da série agregada geram melhores previsões.

**Palavras-chave:** PIB trimestral, desagregação, *Autometrics*, *Markov-Switching*, modelos de espaço-estado, *Model Confidence Set*.

## **ABSTRACT**

The present study aims to compare and combine different forecast techniques for the Brazilian quarterly GDP from 1991 to the second quarter 2014, using aggregated data, and disaggregated data with fixed and stochastic weights. The disaggregated univariate and multivariate models, as well as the stochastic weights, were estimated by Autometrics algorithm created by Doornik (2009), through the disaggregation levels provided by IBGE in the System of National Accounts. The aggregate models were estimated by Autometrics, Markov-Switching and state-space structural models. The forecast comparison methodology was the Model Confidence Set, developed by Hanse, Lunde and Nason (2011). Two simulations were conducted, the first with the analysis out-of-sample from 2008, and the second from 2000, with forecast horizon of up to six steps ahead. The results suggest that the disaggregated models with fixed weights perform better in the first two steps, while in the remaining periods the aggregate models provides superior forecasts.

**Keywords:** Quarterly GDP, disaggregation, Autometrics, Markov-Switching, state-space models, Model Confidence Set.

## LISTA DE FIGURAS

Figura 3.1: Árvore de procura para um MGI com variáveis ABCD .....	25
Figura 4.1: Exemplo da dinâmica de modelagem e projeção utilizada.....	35
Figura 4.2: Raiz do EQM por horizonte de projeção da Simulação 1 .....	37
Figura 4.3: Raiz do EQM por horizonte de projeção da Simulação 2.....	41

## LISTA DE TABELAS

Tabela 3.1: Visões das desagregações do PIB .....	19
Tabela 3.2: Model Confidence Set p-valor .....	32
Tabela 3.3: Relação dos modelos estimados.....	34
Tabela 4.1: Raiz do EQM da Simulação 1 .....	36
Tabela 4.2: MCS p-valor da Simulação 1 .....	38
Tabela 4.3: Raiz do EQM da Simulação 2 .....	40
Tabela 4.4: MCS p-valor da Simulação 2.....	42



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>10</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>13</b>
2.1	AGREGADO OU DESAGREGADO? EIS A QUESTÃO .....	13
2.2	COMPARAÇÃO DE PROJEÇÕES .....	16
<b>3</b>	<b>METODOLOGIA .....</b>	<b>18</b>
3.1	CONSIDERAÇÕES GERAIS .....	18
3.2	BASES DE DADOS .....	19
3.3	TÉCNICAS DE MODELAGEM.....	20
3.3.1	<i>Modelos Autorregressivos .....</i>	<i>20</i>
3.3.2	<i>Modelos de Mudança de Regime .....</i>	<i>21</i>
3.3.3	<i>Modelos Estruturais de Espaço-Estado.....</i>	<i>21</i>
3.3.3	<i>Modelos VAR.....</i>	<i>22</i>
3.4	AUTOMETRICS .....	23
3.4.1	<i>Introdução .....</i>	<i>23</i>
3.4.2	<i>Funcionamento.....</i>	<i>24</i>
3.5	MODEL CONFIDENCE SET .....	26
3.5.1	<i>Introdução .....</i>	<i>26</i>
3.5.2	<i>Funcionamento.....</i>	<i>28</i>
3.5.3	<i>Testes estatísticos.....</i>	<i>30</i>
3.5.4	<i>O p-valor do MCS.....</i>	<i>31</i>
3.6	MODELOS ESTIMADOS.....	33
<b>4</b>	<b>RESULTADOS .....</b>	<b>35</b>
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>43</b>
	<b>APÊNDICE A - GRÁFICOS DAS SÉRIES UTILIZADAS .....</b>	<b>46</b>
A.1	SÉRIES ENCADEADAS .....	46
A.2	PESOS (VALORES CORRENTES) .....	50
	<b>APÊNDICE B - TESTES DE RAIZ UNITÁRIA.....</b>	<b>55</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>56</b>

## 1 INTRODUÇÃO

O Produto Interno Bruto (PIB) é uma variável econômica de suma relevância como indicadora da atividade econômica agregada de uma região ou país. Definido como sendo o valor de mercado de todos os bens e serviços finais produzidos por um país em um determinado período de tempo, o PIB brasileiro é divulgado trimestralmente pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Podendo ser calculado de três maneiras diferentes (ótica da oferta, ótica da demanda e ótica da renda) através de diversas variáveis que compõem o Sistema de Contas Nacionais, o PIB é o indicador mais utilizado pelos economistas como medida de avaliação do crescimento econômico.

O crescimento econômico é o objetivo principal de todas as nações e é almejado através da busca da sinergia entre a produção, distribuição e consumo de bens e serviços. Quanto maior o crescimento de um país, maiores deveriam ser os benefícios retornados à sociedade como, por exemplo, a geração de empregos, melhoria dos serviços públicos em geral e aumento da qualidade de vida. A informação dos estados nos quais a economia atravessou e atualmente se encontra é crucial para a criação de políticas econômicas, e a construção de modelos empíricos que possam mensurar dados históricos e projetar sua trajetória futura é fundamental para a realização de análises, monitoramentos e críticas dos planos definidos para o desenvolvimento econômico de um país, pois proporciona fundamentações econométricas para o entendimento do processo temporal atrelado ao fenômeno estudado.

Os métodos empíricos aplicados à macroeconomia são extensamente utilizados na literatura. Diversas são as técnicas que foram desenvolvidas para a estimação de processos que sejam uma boa aproximação do que acontece na realidade, tornando assim possível extrapolar para períodos futuros os possíveis resultados da série de interesse. Por se tratarem de projeções, é evidente a existência de erros associados, os quais devem ser bem controlados e satisfazer uma gama de requisitos para que haja segurança nas estimativas, de forma que o estudo e interpretação dos resultados sejam feitos de forma consistente.

Em particular, existe uma extensa literatura acadêmica discutindo a utilização das séries desagregadas de um determinado indicador para a construção de modelos de previsão. Depois de combinadas, estas informações podem fornecer melhores projeções do que a série agregada, ou seja, tais que os erros de projeção sejam menores. Uma vez que a maioria dos indicadores de atividade econômica são formados por diversas componentes, sendo cada uma destas regida por um processo característico próprio, estimam-se modelos que melhor se adaptam a estas especificidades. Assim, realizam-se as projeções de cada componente, para depois recombiná-las de acordo com os pesos associados para obter uma projeção do todo. Entretanto, dependendo do processo gerador dos dados que rege a série econômica, a desagregação pode fornecer resultados inferiores em relação à projeção agregada.

Uma técnica alternativa consiste em incluir as variáveis desagregadas e a série agregada no mesmo modelo econométrico de projeção, ou seja, o resultado depende tanto das defasagens do indicador total quanto das defasagens dos itens que o compõe. Consegue-se mostrar empiricamente que o preditor resultante possui erro menor do que a projeção agregada resultante das estimativas de cada componente desagregada modelada separadamente. Porém, tais resultados não se aplicam em algumas situações de natureza prática.

A maioria dos trabalhos realizados sobre projeção de séries econômicas desagregadas não consideram a propriedade estocástica dos pesos das componentes, isto é, as realizações futuras são estimadas com base em pesos invariantes no tempo. Mesmo assim, os resultados encontrados nestes estudos sugerem que esta abordagem traz vantagens na redução dos erros de projeção. Assim, a construção de técnicas que levam em consideração a mudança dos pesos das componentes da série na modelagem dos dados e projeção de resultados futuros podem levar a resultados mais precisos do ponto de vista econométrico.

O objetivo do presente trabalho consiste então em realizar a modelagem do PIB trimestral brasileiro agregado e desagregado pelas óticas da oferta e da demanda, utilizando diversas técnicas de modelagem de séries temporais lineares e não lineares, de forma que serão construídos modelos da série agregada; de cada

componente para posterior combinação com pesos de agregação fixos e estocásticos, donde os pesos de cada componente serão estimados através de modelos univariados; e da série agregada utilizando dados defasados agregados e desagregados em modelos multivariados. De posse de uma gama de modelos para o indicador total, cada componente e seus respectivos pesos de agregação, serão computadas as projeções para até 6 (seis) períodos para a série do PIB trimestral, as quais serão comparadas para verificação das mais eficientes com relação ao resultado real.

O presente trabalho está organizado em cinco partes, sendo a Seção 1 esta introdução. A Seção 2 contém uma revisão bibliográfica sobre estudos realizados sobre projeções de informações agregadas e desagregadas, e metodologias de comparação do poder preditivo de modelos. Na Seção 3 serão abordadas de maneira breve as diferentes técnicas de modelagem de séries temporais utilizadas, bem como os métodos de comparação e combinação de projeções, além da descrição das bases de dados e tratamentos realizados nas informações. Na Seção 4 serão exibidos e discutidos os resultados da aplicação das técnicas e da avaliação comparativa entre os modelos. E, finalmente, na Seção 5 serão discutidas as limitações e possíveis extensões do trabalho, além da apresentação da conclusão.

## 2 REFERENCIAL TEÓRICO

### 2.1 AGREGADO OU DESAGREGADO? EIS A QUESTÃO

Na literatura econômica, existem diferentes abordagens que podem ser adotadas para a projeção de agregados econômicos. A primeira e mais usual é a utilização direta da série agregada, através da construção de um modelo que seja uma boa aproximação do processo gerador de dados (PGD), e assim calcular as projeções. Alternativamente, podem-se realizar estimações para os PGD dos dados desagregados e, de conhecimento da representatividade de cada componente, agregar as projeções desagregadas. Estatisticamente mais trabalhosa, a argumentação a favor da desagregação envolve a questão do processo agregado não captar as particularidades das partes que o somam, e havendo estimativas para cada uma delas originada de um modelo próprio, ganha-se em eficiência na projeção do todo. Diferentes resultados foram encontrados em testes empíricos realizado por diversos autores, os quais serão discutidos nesta seção.

Uma das primeiras contribuições para o tema foi o trabalho realizado por Grunfeld e Griliches (1960), no qual apresentaram os resultados de dois estudos econométricos, sendo o primeiro uma investigação do comportamento de investimento de firmas, e o segundo uma análise regional e nacional da demanda por fertilizante. Os resultados sugerem que a agregação de variáveis econômicas pode produzir ganhos nas projeções se comparados com as estimativas do indicador agregado. Tiao e Guttman (1980) propõem uma medida de eficiência para a agregação quando as componentes seguem processos de média móvel estacionários, derivam uma condição necessária e suficiente na qual não existem ganhos ao agregar as informações, e estendem os resultados para processos autorregressivos e não estacionários. Outros estudos que investigam o potencial ganho da projeção do indicador agregado pelas estimativas das componentes são realizados por Rose (1977), Kohn (1982), Pesaran, Pierse e Kumar (1989) e Palm e Nijman (1990).

Uma importante argumentação foi estabelecida por Lütkepohl (1984), na qual os resultados encontrados sugerem que, se os processos geradores de dados das componentes e da série agregada são conhecidos, se mostra mais eficiente projetar as séries desagregadas e somá-las de acordo com os pesos individuais. Por outro lado, se os processos envolvidos são desconhecidos, as projeções realizadas utilizando diretamente a variável agregada podem ser preferíveis por fornecerem aproximações mais precisas, evidenciando que, na prática, as hipóteses associadas ao arcabouço teórico podem não ser satisfeitas. Evidências de perda de eficiência na projeção das variáveis desagregadas com relação ao indicador agregado também são encontrados por Hubrich (2005) ao analisar a desagregação por subíndices da inflação da União Européia, sugerindo que os erros de projeção de cada componente não diminuem, e sim aumentam devido aos diferentes choques ocorridos durante o período amostral e, quando agregados, fornecem estimativas viesadas.

Hendry e Hubrich (2011) citam alguns fatores que explicam os desvios do teoricamente esperado, como problemas de especificação dos modelos, os tipos de processos agregados e desagregações associadas, horizontes de observação da amostra selecionada, incertezas associadas às estimações, erros de medida e quebras estruturais. Neste mesmo estudo, demonstram empiricamente que existe redução do erro quadrático médio ao propor uma utilização alternativa das informações desagregadas ao incorporá-las no modelo utilizado para projeção da série agregada, em vez de projetar cada componente separadamente e agregar posteriormente ou utilizar a variável agregada diretamente. No entanto, os testes empíricos sugerem que em algumas situações práticas o esperado não se confirma, e atribuem as diferenças às mudanças nos momentos incondicionais da variável agregada, assim como na colinearidade e nos fatores comuns associados à variância das componentes desagregadas.

Em contrapartida, existem trabalhos que confirmam a evidência de que as projeções de variáveis desagregadas para indicadores agregados podem ser mais eficientes. Espasa, Senra e Albacete (2002) estudaram a desagregação da inflação da União Européia por países e por setores, e os resultados da quebra por setores gerou melhores projeções para todos os horizontes superiores a um mês.

Marcellino, Stock e Watson (2003) investigaram diversos métodos de projeção de quatro variáveis da Zona do Euro: PIB real, produção industrial, inflação e taxa de desemprego. Os testes empíricos utilizando informações desagregadas por país resultaram em melhores projeções dos indicadores de interesse, sugerindo que as diferentes situações políticas e econômicas de cada nação fornecem maior precisão quando tratadas separadamente. Carson, Cenesizoglu e Parker (2010) compararam projeções da demanda por viagens aéreas nos Estados Unidos utilizando um indicador de nível nacional com a agregação das projeções individuais de aeroportos pertencentes ao mercado. Para diferentes horizontes de tempo, as projeções calculadas das séries desagregadas resultaram em melhores aproximações para a demanda pela utilização do transporte aéreo.

A maioria dos estudos de projeção de agregados econômicos pelas componentes consideram os pesos das séries desagregadas como sendo fixas no tempo, e através de um exemplo de taxa de desemprego da União Européia, Lütkepohl (2010, 2011) levanta a questão de qual peso utilizar, dado que a participação de cada país pode variar no tempo, e estabelece um panorama no qual a variação dos pesos é levada em consideração, porém de forma indireta, dado que na prática estas informações podem não ser observáveis ou não serem fornecidas. No entanto, existem diversas variáveis agregadas nas quais os pesos de cada componente são conhecidos historicamente e se encontram à disposição para utilização. Assim, se mostra pertinente avaliar se estes dados computados explicitamente podem fornecer melhores projeções para o indicador de interesse. Brüggemann e Lütkepohl (2013) investigaram a possibilidade de projeções considerando pesos de agregação estocásticos para as componentes produzirem menores erros quadráticos médios, a qual foi confirmada através da utilização de dois exemplos reais. Através de simulações de Monte Carlo, foi confirmado que os ganhos associados às projeções com pesos estocásticos não são espúrios.

No Brasil, a incorporação de dados desagregados foi utilizada por Schwartzman (2006) para estimativas da Curva de Phillips através do método de mínimos quadrados ordinários em três estágios, para uma análise da dinâmica da inflação brasileira. Fonseca (2006), ao estudar o repasse cambial no Brasil no período de flutuação do real, estimou Curvas de Phillips para diversos índices de

preço desagregados no atacado e varejo, encontrando evidências da diferença dos efeitos da taxa cambial em cada um destes índices. Carlos (2012) analisou projeções para o IPCA através da série agregada e dos dados desagregados, encontrando evidências de ganhos de eficiência ao considerar as projeções das componentes do indicador. Martinez e Cerqueira (2013), com o objetivo de analisar os determinantes da estrutura da inflação brasileira, concluíram que a decomposição do IPCA mostra que existem diferenças de comportamento em cada agrupamento, ressaltando a importância do estudo de dados desagregados na economia brasileira.

Em todo o período de pesquisa para a realização deste trabalho, não foram encontrados estudos direcionados à projeção do PIB brasileiro de forma desagregada, comparando diferentes técnicas de utilização das componentes e com o uso de pesos estocásticos para verificar a possibilidade de ganhos na projeção do índice agregado.

## 2.2 COMPARAÇÃO DE PROJEÇÕES

No estudo de séries de tempo, existem informações nas quais mais de uma técnica econométrica pode ser utilizada na modelagem dos dados de interesse, permitindo a obtenção de diferentes projeções para um mesmo indicador. Dentre todos os modelos construídos, não necessariamente todos fornecerão resultados equivalentes. Assim, surge a necessidade de métodos de comparação do poder preditivo dos modelos aplicados ao processo estudado. A busca pela melhor projeção, ou conjunto de melhores projeções, é essencial para oferecer direcionamento e fundamentação estatística nos processos de entendimento dos fenômenos econômicos e tomadas de decisão.

O desenvolvimento de uma metodologia de comparação de projeções diferentes modelos envolve analisar o conceito de erro da estimativa, isto é, a diferença entre o valor real da informação e o valor aproximado pelo modelo, avaliado através de uma função perda, dentre as quais se destacam o erro quadrático médio e o erro absoluto médio. O trabalho desenvolvido por Granger e Newbold (1977) é considerado um dos primeiros em verificação da acurácia de



projeções derivadas de dois modelos diferentes. Os autores, inspirados no estudo de Morgan (1939), criaram duas variáveis, uma com a soma e outra com a subtração dos erros das projeções, e desenvolveram um teste comparativo cuja hipótese nula é a verificação da igualdade da precisão das estimativas. Meese e Rogoff (1988) propuseram uma modificação do teste de equivalência, para considerar a correlação temporal e contemporânea entre os erros das projeções. O trabalho de Diebold e Mariano (1995) expandiu ainda mais o universo de análise comparativa ao permitir a aplicação direta de funções perda não-quadráticas, erros cujas distribuições não são gaussianas e com média diferente de zero, e projeções para mais de um período, seguido pela modificação sugerida por Harvey, Leybourne e Newbold (1997), a qual oferece um melhor tratamento para os casos com amostras pequenas.

Na literatura também existem uma série de trabalhos que contribuíram para avaliação da capacidade preditiva dos modelos, dentre eles o realizado por West (1996), que desenvolve uma teoria assintótica e estabelece uma metodologia para testar a capacidade preditiva dos modelos, dado que a maioria dos estudos até então realizavam testes comparativos em modelos cujos parâmetros eram estimados, e não consideravam explicitamente a incerteza das projeções associadas à estimações dos parâmetros. Seguindo este raciocínio, White (2000) propõe um método de avaliação da superioridade preditiva de modelos quando comparados a um *benchmark*, realizando tratamentos que levam em conta o reuso das informações (*data snooping*), através de simulações de Monte Carlo e técnicas de *bootstrapping*. Corradi, Swanson e Olivetti (2001) estendem as análises realizadas por Diebold e Mariano (1995), West (1996) e White (2000) ao incorporar as relações de cointegração entre as variáveis.

O procedimento *Model Confidence Set*, proposto por Hansen, Lunde e Nason (2011), possui uma vantagem competitiva com relação aos outros métodos por não necessariamente precisar de um *benchmark* para realizar as comparações entre os objetos. Difere também por ter a funcionalidade determinar um melhor modelo ou grupo de melhores modelos dado um nível de significância, dependendo de quão informativa seja a base de dados. O seu funcionamento será melhor detalhado na Seção 3.8 deste trabalho.

### 3 METODOLOGIA

#### 3.1 CONSIDERAÇÕES GERAIS

O presente trabalho será realizado utilizando modelos de séries temporais estimados através das técnicas de seleção automática (*Autometrics*), de mudança de regime (*Markov-Switching*), e de modelos estruturais de espaço-estado para as informações do PIB agregado. Para as componentes do PIB, tanto na ótica da oferta quanto na ótica da demanda, e na aplicação de pesos estocásticos, também serão utilizados modelos autorregressivos, através do *Autometrics*. Os pesos fixos para as projeções das componentes serão assumidos como iguais ao mesmo período do ano anterior, ou como a média simples dos pesos do ano anterior da amostra de construção dos modelos. Os modelos VAR para o indicador agregado utilizando as informações agregadas e serão estimados via *Autometrics*.

Após a estimação de todas as projeções em até seis trimestres do conjunto de modelos descritos acima, será utilizada a metodologia *Model Confidence Set* (MCS) para a comparação destas estimativas e seleção do melhor modelo, ou grupo de melhores modelos. Desenvolvida por Hansen, Lunde e Nason (2011), esta técnica foi construída de modo que a limitação do conjunto de dados é devidamente reconhecida e tratada, e dado que o teste estatístico de comparação entre as múltiplas projeções é feito de forma eliminatória, existe a possibilidade do resultado final conter mais de um modelo classificado como eficiente.

Os softwares e pacotes estatísticos/econométricos utilizados para a realização deste trabalho são:

- Microsoft Excel, para junção e tratamento de bases, construção de tabelas e gráficos;
- *Oxmetrics6* (pacotes *PcGive*, *STAMP* e *MulCom*) e *Eviews7*, para análise gráfica, testes estatísticos, construção dos modelos e comparação das projeções.

### 3.2 BASES DE DADOS

As informações do PIB trimestral brasileiro agregado e desagregado utilizadas na elaboração deste trabalho foram extraídas do portal Ipeadata, compreendendo o período do primeiro trimestre de 1991 até o segundo trimestre de 2014, após a revisão realizada pelo IBGE em Agosto/2014. As desagregações do PIB estão disponibilizadas na Tabela 3.1 abaixo:

*Tabela 3.1: Visões das desagregações do PIB*

PIB - Ótica da Oferta	PIB - Ótica da Demanda
Impostos sobre produtos (N1) <i>PIB a preços básicos (*)</i> Agropecuária (N1) Indústria (N1) Extrativa mineral (N2) Transformação (N2) Construção (N2) Produção e distribuição de eletricidade, gás e água (N2) Serviços (N1) Comércio (N2) Transporte, armazenagem e correio (N2) Serviços de informação (N2) Intermediação financeira, previdência complementar (N2) Outros serviços (N2) Atividades imobiliárias e aluguel (N2) Administração, saúde e educação públicas (N2) <i>Dummy financeiro (*)</i>	Consumo final (N1) Famílias (N2) Governo (N2) Formação bruta de capital (N1) <i>Formação bruta de capital fixo (*)</i> <i>Variação de estoque (-) (*)</i> Exportações de bens e serviços (N1) Importações de bens e serviços (-) (N1)

Fonte: Ipeadata - Contas Nacionais Trimestrais.

As composições do PIB trimestral pela ótica da renda não se encontravam disponíveis no site do Ipeadata no momento da extração, e na realização da pesquisa não foi encontrado nenhum outro repositório no qual contivesse estas informações. Portanto, no presente estudo serão consideradas apenas desagregações pelas óticas da oferta e da demanda.

Como pode ser observado na Tabela 3.1, ao lado de cada componente sob as duas óticas possui uma marcação entre parênteses, na qual basicamente indica o primeiro (N1) ou segundo (N2) nível de desagregação a ser considerado para a estimação dos modelos. As séries marcadas com (\*) não serão utilizadas neste trabalho, seja por possuir valores semelhantes ao PIB e assim não contribuir dentro do contexto deste trabalho (PIB a preços básicos), por problemas de valores

extremos (Variação de estoque), ou por não conter seu complementar habilitado para equalizar os pesos em seu subgrupo (Formação bruta de capital fixo). O índice de dummy financeiro, por ser um setor fictício a criado pelo IBGE para acertar o batimento do PIB ao contabilizar custos financeiros medidos indiretamente sobre qualquer um dos grandes setores (agropecuária, indústria e serviços), não foi considerado na análise por ter sido encerrado em 1995.

Cada uma das componentes do PIB trimestral brasileiro nas visões acima apresentadas, com exceção daquelas marcadas com (\*), contém o índice encadeado (média 1995 = 100) não-dessazonalizado para estimação do nível do PIB, e informações de valores correntes para o cálculo do peso de cada indicador desagregado em relação ao valor total do PIB.

Todas as variáveis utilizadas para a construção dos modelos foram logaritmizadas (LOG), e em seguida foram calculadas as primeiras diferenças do logaritmo (DLOG). Os gráficos para os índices encadeados do agregado e das componentes, bem como seus respectivos pesos calculados, estão disponibilizados no Apêndice A. Para verificar a estacionariedade das séries (em DLOG), foi aplicado o teste de raiz unitária ADF (*Augmented Dickey–Fuller*) em cada uma delas, cujos resultados estão tabelados no Apêndice B.

### 3.3 TÉCNICAS DE MODELAGEM

#### 3.3.1 Modelos Autorregressivos

Na literatura de séries temporais, foram desenvolvidas diversas técnicas de modelagem ao longo dos anos. Em particular, os modelos do tipo autorregressivos são bastante utilizados na econometria, nos quais a variável dependente é estimada como sendo uma combinação linear de seus valores defasados. É a regressão da variável sobre ela mesma, daí a origem do termo ‘autorregressivo’. É um caso particular dos modelos *ARMA* (autorregressivo e média móvel), popularizados na literatura graças à metodologia desenvolvida por Box e Jenkins (1976). Recomenda-se, além da referência inicial, a leitura de Hamilton (1994) e Enders (1995) para

maiores detalhes na utilização desta técnica. No presente trabalho, os modelos autorregressivos serão utilizados via *Autometrics*.

### 3.3.2 Modelos de Mudança de Regime

Os modelos de mudança de regime (ou *Markov-Switching*) são modelos não-lineares que surgiram para tentar capturar a existência de comportamentos distintos durante a extensão temporal do processo analisado, atrelando uma probabilidade transição entre regimes condicionada à defasagem imediatamente anterior. Tal metodologia, proposta inicialmente por Hamilton (1989), considera que a economia não possui uma mesma dinâmica em períodos de crises financeiras ou em mudanças nas políticas econômicas propostas pelo governo. Isto é, apenas um único processo não se mostra suficiente para modelar o indicador de interesse.

Na literatura existem diversos estudos que utilizam técnicas de *Markov-Switching* para modelagem de séries econométricas, e dentro do contexto deste trabalho destaca-se o realizado por Chauvet (2002), no qual a metodologia foi aplicada na série trimestral do PIB entre 1980 e 2000 para analisar os diferentes ciclos de expansão e recessão da economia brasileira. Os resultados sugerem que na economia brasileira as recessões, bem como os ciclos de crescimento modesto são abruptos e de curta duração, enquanto os períodos de crescimento acelerado são mais longos e graduais.

Neste trabalho, as estimações dos modelos de *Markov-Switching* para a primeira diferença do logaritmo natural do PIB agregado serão realizadas pelo *Oxmetrics6*, através do pacote *PcGive*, limitando em 1 (um) o número de defasagens da parte autorregressiva e de média móvel, regimes distintos na variância, e com constantes sazonais centradas em zero.

### 3.3.3 Modelos Estruturais de Espaço-Estado

Na economia, com frequência existem fenômenos com propriedades dinâmicas que não são observáveis, ou seja, variáveis cuja mensuração não pode

ser realizada de forma direta nos dados coletados, mas cuja influência se mostra importante para o correto entendimento do processo estudado. Ao comportamento não-observável de uma série de tempo se dá o nome de *estado*, o qual pode conter diversas componentes. A abordagem de espaço-estado de uma série de tempo consiste em construir modelos que estimam a dinâmica de cada componente separadamente, para posteriormente juntá-los e obter um modelo de espaço-estado.

No presente estudo, para estimação do logaritmo natural da série agregada do PIB trimestral será utilizado um modelo estrutural, isto é, um modelo de espaço-estado tal que a série de tempo pode ser separada em termos distintos, com cada um deles seguindo um determinado tipo de comportamento, como tendência (composta por nível e inclinação), sazonalidade, ciclo e irregular. Será também estimado um modelo estrutural para a primeira diferença do logaritmo natural do indicador agregado do PIB, no qual apenas a inclinação será desativada. Informações e detalhamentos sobre modelos estruturais de espaço-estado se encontram disponíveis em Harvey e Shephard (1993), e Commandeur e Koopman (2007). O pacote utilizado para a construção dos modelos estruturais é o *STAMP*, disponível no *OxMetrics6*, no qual será habilitada a detecção automática de valores extremos (*outliers*).

### 3.3.3 Modelos VAR

Na dinâmica econômica de séries temporais, muitas vezes as interações entre os diversos indicadores possuem uma interdependência não capturada pelos modelos univariados. Os modelos de vetores autorregressivos (VAR) se popularizaram na década 80 na economia devido em grande parte ao trabalho de Sims (1980), no qual sua utilização é recomendada por não possuírem condições e limitações que dependam de algum conhecimento *a priori* das variáveis, como a maioria dos modelos empíricos desenvolvidos até então no campo macroeconômico. Detalhes sobre o desenvolvimento e estimação dos modelos VAR podem ser encontrados em Hamilton (1994) e Enders (1995).

Neste trabalho, os modelos VAR são utilizados para estimar o indicador agregado incorporando as informações desagregadas, seguindo o raciocínio desenvolvido no trabalho realizado por Hendry e Hubrich (2011). Serão 2 modelos irrestritos, isto é, com intercepto e inclinação diferentes em cada equação, estimados pelo *Autometrics*.

### 3.4 AUTOMETRICS

#### 3.4.1 Introdução

O estudo de fenômenos econômicos para o desenvolvimento de modelos quantitativos é, na maioria das vezes, uma tarefa árdua para o econometrista. O trabalho de encontrar a melhor aproximação para os dados coletados e oferecer um suporte empírico e estatístico para o processo estudado envolve diversos fatores, como a disponibilidade das informações, a dinâmica do evento de interesse e sua interação com outras entidades, mudanças políticas, sociais e estruturais, inovações tecnológicas, revisões metodológicas, entre outros. Assim, surgiram com o passar dos anos diversas escolas que desenvolveram procedimentos para o tratamento econométrico de séries econômicas, cada uma com seus pontos fortes e desvantagens.

Dentre as diferentes metodologias, a abordagem conhecida na literatura como LSE (*London School of Economics*) tem como princípio o conceito de modelo geral para o específico. O modelo inicial (geral) é aquele que contempla todas as variáveis disponíveis que, a princípio, são candidatas como necessárias para aproximar o processo gerador de dados (PGD) de interesse. Caso exista um modelo mais parcimonioso, isto é, uma equação mais simples na qual as variáveis estatisticamente não-significantes sejam descartadas, tal que satisfaça os critérios de abrangência e diagnóstico adotados e que não haja perda de compreensão do fenômeno, esta representação mais compacta (específica) será a escolhida.

O procedimento de seleção de modelos com a abordagem da LSE oferece um desafio computacional por envolver estimações, testes estatísticos e

diagnósticos nos diversos submodelos gerados a partir do modelo geral, e realizar todas estas etapas manualmente é um processo extremamente demorado e sujeito a erros. O trabalho de Hoover e Perez (1999) foi pioneiro ao desenvolver um algoritmo de seleção automática de modelos, cujos resultados se mostraram favoráveis e encorajadores no que se refere à aplicação da metodologia da LSE para modelagem econométrica. A atenção aos aspectos teóricos e melhorias implementadas por Hendry e Krolzig (1999, 2003, 2005) também foram importantes para o crescimento do interesse na utilização desta técnica para modelagem de dados econômicos. A mais recente evolução da técnica de seleção automática de modelos é um procedimento chamado de *Autometrics*. Alicerçado pelos trabalhos antecessores na área, Doornik (2009) elaborou um algoritmo com diversas melhorias, tornando-o computacionalmente mais abrangente e eficiente do que os outros procedimentos até então utilizados em econometria.

#### 3.4.2 Funcionamento

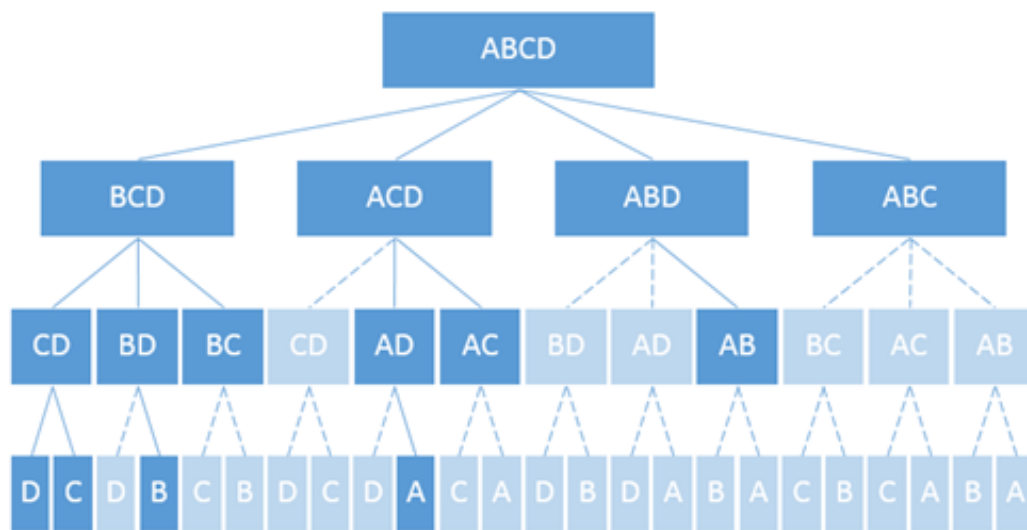
O algoritmo *Autometrics* tem como pré-requisito a especificação de um Modelo Geral Irrestrito (MGI), ou seja, um modelo geral que seja uma boa representação dos dados, o qual servirá como ponto de partida na aplicação do algoritmo. Dado que a seleção automática de modelos parte do MGI, é importante ressaltar que a má especificação do MGI não necessariamente resultará em um modelo final estatisticamente eficiente e economicamente viável. Isto posto, é papel do econometrista garantir a interpretação e validade dos resultados obtidos.

De posse do MGI, estipula-se um nível de significância para redução do modelo ao qual são submetidas todas as variáveis que, caso estatisticamente não-significantes, são eliminadas. Este parâmetro também especifica a tolerância com relação à perda da informação do modelo parcimonioso com relação ao geral. O processo de avaliação do conjunto de submodelos envolve a construção de uma árvore de busca, na qual cada ramo representa um modelo (Figura 3.1). No ramo, são realizados testes da significância dos coeficientes das variáveis e da perda de informação com relação ao MGI. Sendo todos os coeficientes forem estatisticamente diferentes de zero e o modelo simplificado representar bem os dados, testes de



diagnóstico (autocorrelação, normalidade, heterocedasticidade e especificação) são realizados para assegurar a correta determinação do modelo. Caso algum teste não seja satisfeito, o modelo atual é rejeitado, os modelos subsequentes não são avaliados, e o modelo do ramo imediatamente anterior é definido como terminal para o caminho corrente. O conjunto de modelos terminais encontrado é agrupado, formando um novo MGI, o qual é submetido à árvore de busca. O processo iterativo tem seu fim quando o novo MGI é igual ao MGI anterior. No próximo estágio do algoritmo, mais de um modelo terminal é candidato a ser o modelo final, dado que todos os finalistas são simplificações válidas do MGI inicial. O desempate é então realizado através da aplicação de um critério de informação nos modelos, no qual o que possuir o menor valor é escolhido como modelo final, ou é realizada a união dos modelos terminais.

*Figura 3.1: Árvore de procura para um MGI com variáveis ABCD*



Fonte: elaboração própria.

Para assegurar a eficiência computacional, o algoritmo possui uma série de funcionalidades, como as opções de pré-procura de defasagens e variáveis não-significantes antes de submeter o modelo ao processo da árvore de decisão, o controle no qual ramos repetidos não são estimados novamente, e a possibilidade da eliminação de blocos de variáveis através da estimação de testes conjuntos de significância. Maiores detalhes do funcionamento do *Autometrics* podem ser encontrados em Doornik (2009) e Hendry & Doornik (2013).

Neste trabalho, será utilizado o *Autometrics* implementado no pacote *PcGive* disponível no *Oxmetrics6*, com nível de significância  $p = 0.01$  para a estimação de modelos autorregressivos da primeira diferença do logaritmo natural do indicador agregado, das componentes, dos pesos das componentes, e do modelo multivariado contendo a série agregada e suas desagregações. Todos os MGI terão inicialmente até 6 defasagens, com a opção de pré-procura de defasagem habilitada. Nestes modelos serão adicionadas constantes sazonais centradas com média zero (*CSeasonal*) em sua composição, na tentativa de capturar melhor os efeitos de sazonalidade, uma vez que o intercepto está associado diretamente à taxa de crescimento. Além disso, os modelos serão habilitados a utilizar saturação por *dummies* na identificação de *outliers*. O conceito de *dummies* de saturação, introduzido por Hendry, Johansen e Santos (2008), consiste basicamente em criar uma *dummy* para cada observação da base de dados, e através do procedimento de modelagem geral para específica, remover aquelas que sejam estatisticamente não significantes.

### 3.5 MODEL CONFIDENCE SET

#### 3.5.1 Introdução

O *Model Confidence Set* (MCS) é uma metodologia de seleção de modelos desenvolvida por Hansen, Lunde e Nason (2011) para identificação dos mais adequados dado um nível de confiança pré-estabelecido. Diferente das outras metodologias de avaliação, que realizam as comparações entre pares e resultam em apenas um único modelo final, o MCS permite aferir todos os modelos disponíveis sequencialmente e, dependendo da natureza da base de dados, pode vir a ter mais de um modelo como resultado da aplicação do procedimento.

O MCS também leva em consideração a limitação das informações disponíveis, gerando uma coleção de diversos modelos caso os dados coletados para a construção não sejam explicativos, podendo chegar ao extremo de conter todos os elementos do conjunto inicial. Sendo a base informativa, um pequeno grupo de melhores modelos ou apenas um modelo pode vir a resultar da utilização do

MCS, sendo sua interpretação equivalente àquela realizada para um intervalo de confiança de um parâmetro populacional estimado por inferência padrão. É importante ressaltar que a palavra “modelo” é apenas uma generalização semântica, visto que o MCS pode ser aplicado na avaliação de modelos econométricos, projeções em diversos horizontes, além de outras informações que não necessariamente precisam de tratamentos de modelagem dos dados, como, por exemplo, as regras de *trading* no mercado financeiro.

O algoritmo implantado no MCS compreende basicamente no emprego de um teste de equivalência e de uma regra de eliminação no grupo de modelos a ser avaliado através da performance relativa com relação a uma função perda associada. O critério de avaliação empírica do procedimento tem início na execução do teste de equivalência para o conjunto inicial de modelos. Caso o teste seja rejeitado, existem evidências de que algum dos modelos disponibilizados não é suficiente para representar as informações de forma satisfatória, segundo o nível de significância aplicado. Assim sendo, a aplicação da regra de eliminação tem como objetivo descartar o modelo da coleção com o pior desempenho para a amostra coletada. O processo iterativo é repetido até que o teste de equivalência não seja rejeitado, e os modelos que se mantiveram dentro das especificações são classificados como o MCS dos dados nos quais foram construídas as estimativas.

A ideia do procedimento sequencial realizado no MCS para encontrar os modelos com desempenho superior é semelhante ao princípio aplicado no teste do traço realizados para encontrar o posto de uma matriz, como na metodologia desenvolvida por Johansen (1988) para identificar as relações de cointegração entre as variáveis de um modelo autoregressivo multivariado. A diferença está no fato de que, enquanto no teste do traço existe uma ordem inerente ao algoritmo para as hipóteses serem testadas, no MCS o fluxo de testes tem como pré-requisito a aplicação de uma regra de eliminação para o descarte do modelo com performance considerada insuficiente. A implantação deste algoritmo envolve o emprego da técnica de *bootstrapping* anteriormente utilizada por White (2000), aplicada neste contexto tanto pela simplicidade e praticidade do método, quanto pela vantagem de contemplar o tratamento das perturbações dos parâmetros a serem estimados cujas distribuições não são consideradas padrão.

### 3.5.2 Funcionamento

Seja  $C^0$  o conjunto inicial de modelos indexados por  $i = 1, 2, \dots, m$  a ser submetido ao procedimento do MCS dentro do intervalo de tempo  $t = 1, 2, \dots, n$ . A avaliação destes objetos está associada à definição de uma função perda  $L_{i,t}$  tal que forneça uma medida do desempenho do modelo  $i$  no período de tempo  $t$  em relação aos dados informacionais coletados. Seja  $d_{(i,j),t} = L_{i,t} - L_{j,t}$  a medida de performance relativa válida para qualquer  $i, j \in C^0$ . Assumindo que  $\mathbb{E}(d_{(i,j),t}) = \mu_{ij}$  seja um valor finito e independente do tempo  $t$ , espera-se que  $\mu_{i,j} < 0$  para o modelo  $i$  ser preferível ao modelo  $j$  em termos da função perda adotada. O conjunto  $C^*$  de melhores modelos é definido por

$$C^* \equiv \{i \in C^0 : \mu_{ij} \leq 0 \text{ para todo } j \in C^0\}.$$

A determinação de  $C^*$  envolve a aplicação de uma sequência de testes de equivalência  $\delta_C$  para verificar se existem elementos que sejam inferiores a outros dentro do conjunto analisado, ou seja, objetos que não satisfaçam a hipótese nula do seguinte teste:

$$\begin{cases} H_{0,C}: \mu_{ij} = 0 \text{ para todo } i, j \in C, \text{ tal que } C \subset C^0 \\ H_{A,C}: \mu_{ij} \neq 0 \text{ para algum } i, j \in C, \text{ tal que } C \subset C^0 \end{cases}$$

Quando a hipótese nula  $H_{0,C}$  não é rejeitada, assume-se que  $\delta_C = 0$ , o processo é encerrado, e o grupo  $\check{C}_{1-\alpha}$  de modelos não eliminados caracteriza o *Model Confidence Set* para as informações submetidas ao algoritmo. Caso se rejeite  $H_{0,C}$ , convencionou-se que  $\delta_C = 1$ , e o passo seguinte é caracterizado pela execução da regra de eliminação  $\epsilon_C$  para identificar e remover do conjunto  $C$  o objeto com desempenho insatisfatório. Para que o teste de hipóteses acima seja estatisticamente bem fundamentado e  $\check{C}_{1-\alpha}$  possua uma interpretação equivalente a um intervalo de confiança na inferência tradicional,  $\delta_C$  e  $\epsilon_C$  devem satisfazer alguns requerimentos, os quais estão descritos na suposição abaixo:

Suposição 3.1: Para qualquer conjunto  $C \subset C^0$ , assume-se que  $\delta_C$  e  $\epsilon_C$  satisfaçam as seguintes propriedades assintóticas:

- a)  $\limsup_{n \rightarrow \infty} \mathbb{P}(\delta_C = 1 | H_{0,C}) \leq \alpha;$
- b)  $\lim_{n \rightarrow \infty} \mathbb{P}(\delta_C = 1 | H_{A,C}) = 1;$
- c)  $\lim_{n \rightarrow \infty} \mathbb{P}(\epsilon_C \in C^* | H_{A,C}) = 0.$

O item (a) diz respeito ao erro de tipo I do teste de hipótese tradicional, ou seja, de que a probabilidade de rejeitar a hipótese nula quando ela é verdadeira seja menor ou igual ao nível significância  $\alpha$ , o item (b) refere-se à convergência para 1 da probabilidade de rejeitar a hipótese nula quando a mesma for falsa, e o item (c) estabelece que a chance de um objeto inferior pertencer ao conjunto de melhores modelos dada a rejeição de  $H_{0,C}$  seja assintoticamente nula. Considerando que  $\delta_C$  e  $\epsilon_C$  estão de acordo com estes três requerimentos, a utilização do termo '*Model Confidence Set*' para a coleção  $\check{C}_{1-\alpha}$  se mostra apropriada devido ao Teorema 1 enunciado a seguir:

Teorema 3.1: Suponha que a Suposição 3.1 esteja satisfeita. Então, segue que:

- a)  $\liminf_{n \rightarrow \infty} \mathbb{P}(C^* \subset \check{C}_{1-\alpha}) \geq 1 - \alpha;$
- b)  $\lim_{n \rightarrow \infty} \mathbb{P}(i \in \check{C}_{1-\alpha}) = 0, \text{ para todo } i \notin C^*.$

Uma demonstração completa do Teorema 1 está disponível no trabalho Hansen, Lunde e Nason (2011). Assim, estando estabelecida a fundamentação introdutória do algoritmo do MCS, pode-se resumir seu funcionamento da seguinte forma:

- Passo 0: Estruturar a coleção inicial de objetos  $C^0$ ;
- Passo 1: Definir  $C = C^0$  e o nível de significância  $\alpha$  para o teste  $\delta_C$ ;
- Passo 2: Utilizar  $\delta_C$  para verificar a não rejeição de  $H_{0,C}$ ;
- Passo 3: Caso  $H_{0,C}$  não seja rejeitada, definir  $\check{C}_{1-\alpha} = C$  e encerrar o algoritmo. Senão, executar  $\epsilon_C$  e repetir o procedimento a partir do passo 1.

### 3.5.3 Testes estatísticos

A implementação do teste estatístico do MCS utiliza métodos de *bootstrapping*, cuja aplicação está assegurada com a adoção da premissa de que as performances relativas  $\{d_{(i,j),t}\}_{i,j \in C^0}$  sejam estritamente estacionárias mesmo que existam fenômenos econômicos diversos, como quebras estruturais, que possam resultar em funções perda  $\{L_{i,t}\}_{i \in C^0}$  integradas de ordem maior ou igual a um. Assim, espera-se que todos os objetos do conjunto  $C^0$  se comportem frente aos eventos de maneira similar, preservando a estacionariedade de  $\{d_{(i,j),t}\}_{i,j \in C^0}$ .

Seja  $\bar{d}_{ij} = \frac{1}{n} \sum_{t=1}^n d_{(i,j),t}$  a performance relativa média temporal entre os modelos  $i, j \in C$  em , e  $\bar{d}_i = \frac{1}{m} \sum_{j \in C} \bar{d}_{ij}$  a média de desempenho do modelo  $i$  levando em consideração todas as performances relativas médias temporais com todos os outros modelos do conjunto  $C$ . A partir destas duas variáveis, definem-se as seguintes estatísticas:

$$t_{ij} = \frac{\bar{d}_{ij}}{\sqrt{\hat{V}(\bar{d}_{ij})}} \quad \text{e} \quad t_i = \frac{\bar{d}_i}{\sqrt{\hat{V}(\bar{d}_i)}}, \quad \text{para } i, j \in C,$$

em que  $\hat{V}(\bar{d}_{ij})$  e  $\hat{V}(\bar{d}_i)$  são as estimativas das variâncias de  $\bar{d}_{ij}$  e  $\bar{d}_i$ , respectivamente. A hipótese nula  $H_{0,C}$  é equivalente à expressão  $\mathbb{E}(\bar{d}_{ij}) = 0$  para todo  $i, j \in C$ , e também equivalente à  $\mathbb{E}(\bar{d}_i) = 0$  para todo  $i \in C$ . Assim, as estatísticas de teste  $T_R = \max_{i,j \in C} |t_{ij}|$  e  $T_{MAX} = \max_{i \in C} t_i$  podem ser utilizadas para a realização do teste de hipóteses do MCS incorporado ao teste de equivalência  $\delta_C$ . Vale ressaltar que as distribuições assintóticas de  $T_1$  e  $T_2$  não possuem comportamento padrão devido às perturbações dos parâmetros associados às hipóteses nula e alternativa, no entanto os procedimentos de *bootstrapping* utilizados estão aptos a tratar estas particularidades.

A aplicação da regra de eliminação no MCS depende da estatística de teste utilizada. Caso seja  $T_R$ , tem-se que  $\epsilon_C = \arg \max_{i \in C} \sup_{j \in C} t_{ij}$ . Por outro lado, se a variável

escolhida for  $T_{MAX}$ , a regra de eliminação definida é  $\epsilon_C = \arg \max_{i \in C} t_i$ . Pode-se verificar que a concepção da segunda estatística é natural, pois remove do conjunto  $C$  o objeto que mais contribui para a magnitude das estatísticas de teste, na situação em que a hipótese nula  $H_{0,C}$  atrelada ao teste de equivalência  $\delta_C$  é rejeitada.

#### 3.5.4 O p-valor do MCS

Seja  $C^{(k)} = \{k, k + 1, \dots, m\}$  a coleção de modelos de tal forma que a aplicação da regra de eliminação  $\epsilon_{C^{(k)}} = k$ , para  $k = 1, 2, \dots, m$ , remova o objeto com desempenho insatisfatório na rejeição da hipótese nula  $H_{0,C^{(k)}}$ . Esta atribuição para os conjuntos de modelos avaliados pelo teste de equivalência  $\delta_C$  garante que  $\epsilon_{C^{(1)}} = 1$  seja o primeiro modelo a ser eliminado,  $\epsilon_{C^{(2)}} = 2$  o segundo, e assim sucessivamente. Assim, pode-se utilizar a seguinte definição:

**Definição 3.1:** *Seja  $p_{(k)}$  o p-valor associado à hipótese  $H_{0,C^{(k)}}$ , com a convenção de que  $p_{(m)} \equiv 1$ . O p-valor do MCS do modelo  $i \in C^0$  é definido por  $\hat{p}_i \equiv \max_{k \leq i} p_{(k)}$ .*

A utilização da definição acima, juntamente com o Teorema 3.2 enunciado abaixo e demonstrado em Hansen, Lunde e Nason (2011), permite estabelecer a relação entre o p-valor da hipótese  $H_{0,C^{(k)}}$  com o p-valor do MCS, a qual permite calcular os valores disponibilizados na Tabela 3.2.

**Teorema 3.2:** *Seja  $C^0$  o conjunto de modelos indexados por  $i = 1, 2, \dots, m$ . O p-valor do MCS,  $\hat{p}_i$ , é tal que  $i \in \check{C}_{1-\alpha}$  se, e somente se,  $\hat{p}_i > \alpha$  para  $\forall i \in C^0$ .*

A forma de se interpretar a coleção  $\check{C}_{1-\alpha}$  resultante da seleção pelo MCS é equivalente à utilizada na inferência tradicional. Assim, havendo estabelecido um nível de confiança de  $(1 - \alpha)$ , a probabilidade que o conjunto  $\check{C}_{1-\alpha}$  contenha os objetos de  $C^*$  é não inferior a  $(1 - \alpha)$ , ou seja, existe evidência estatística que, dentro do grupo de modelos sobreviventes decorrente da aplicação do procedimento, estão aqueles que são mais eficientes para explicar as informações de interesse. Para maiores detalhes teóricos e demonstrações, o trabalho de

Hansen, Lunde e Nason (2011) contem as informações para o entendimento do *Model Confidence Set*.

*Tabela 3.2: Model Confidence Set p-valor*

Regra de Eliminação $\epsilon_{C(k)} = k$	p-valor de $H_{0,C(k)}$ $p_{(k)}$	p-valor do MCS $\hat{p}_i \equiv \max_{k \leq i} p_{(k)}$
1	0.01	0.01
2	0.04	0.04
3	0.02	0.04
4	0.03	0.04
5	0.07	0.07
6	0.04	0.07
7	0.11	0.11
8	0.25	0.25
$\vdots$	$\vdots$	$\vdots$
$m$	1.00	1.00

Fonte: Hansen, Lunde e Nason (2011)

A rotina *MulCom* (*Multiple Comparison*), disponibilizada como um pacote compatível com o *Oxmetrics6*, foi utilizada para aplicação do MCS nas projeções do PIB brasileiro agregado e desagregado, utilizando as técnicas de modelagem desenvolvidas neste capítulo. O nível de significância definido foi  $\alpha = 0.1$ , a estatística de teste escolhida foi  $T_{MAX}$  pela facilidade do entendimento de sua definição, e a função perda utilizada para cada modelo foi a do Erro Quadrático Médio (EQM), definida abaixo:

$$EQM_i = \frac{1}{r} \sum_{j=1}^r (y_j - \hat{y}_{i,j})^2,$$

em que  $i = 1, 2, \dots, m$  é a quantidade de modelos,  $r$  denota o número de observações na base de dados,  $y_j$  é a variável de interesse observada no período  $j$ , e  $\hat{y}_{i,j}$  é a estimativa gerada pelo modelo modelo  $i$  no tempo  $j$ .



### 3.6 MODELOS ESTIMADOS

De posse da base de dados, das visões de desagregação, das técnicas de modelagem de séries temporais a serem utilizadas e da metodologia de comparação de projeções, o próximo passo é listar quais serão os modelos submetidos à avaliação comparativa. Sabe-se que a aplicação dos modelos univariados é direta, no entanto é preciso esclarecer alguns pontos sobre a utilização das estimativas provenientes dos modelos estimados para as componentes do PIB: a apuração dos pesos e o agrupamento das informações desagregadas.

Para a definição dos pesos, foram utilizadas as informações de valores correntes e a realização se deu de três maneiras, sendo a primeira relativa à média do ano anterior, dado que no histórico contenha os 4 trimestres; a segunda relativa ao mesmo trimestre do ano recente mais disponível na base de modelagem; e a terceira via *Autometrics*, como mencionado anteriormente. Assim, são utilizadas duas abordagens de pesos fixos e uma de pesos estocásticos, de maneira que a atualização destes valores está condicionada às novas observações que vão sendo acrescentadas na base de modelagem para a estimativa dos modelos. Para assegurar que o total dos pesos estocásticos seja sempre igual a uma unidade em seus respectivos níveis de desagregação, foi construído um processo que verifica se a soma das contribuições é diferente de 1. Caso positivo, cada peso será dividido pelo valor desta soma para a padronização das ponderações.

As séries utilizadas para estimar o PIB e suas desagregações são encadeadas, e apesar da adoção de índices em cadeia possuir vantagens ao incorporar os movimentos de variação da quantidade do produto, a propriedade da aditividade não é mais assegurada, isto é, o índice total não é igual à média ponderada dos índices de cada componente. Desta forma, a construção da projeção do indicador agregado formada pela junção das projeções dos setores desagregados foi realizada de forma que o PIB no período  $t$  seja uma ponderação do crescimento de cada uma de suas componentes multiplicado nível do agregado em  $t - 1$ , ou seja,

$$\frac{PIB_t}{PIB_{t-1}} = \sum_{i=1}^N w_{i,t} \frac{I_{i,t}}{I_{i,t-1}} \Rightarrow PIB_t = \left( \sum_{i=1}^N w_{i,t} \frac{I_{i,t}}{I_{i,t-1}} \right) PIB_{t-1},$$

em que  $I_{i,t}$  é o nível do índice da componente,  $w_{i,t}$  é o peso da componente e  $N$  a quantidade de componentes para o nível de desagregação avaliado.

Assim, tendo esclarecido o método de construção das estimativas originadas de modelos das desagregações do índice do PIB, sejam elas com pesos fixos ou estocásticos, segue na Tabela 3.3 abaixo a lista de modelos utilizados para a comparação de projeções até 6 passos à frente. Vale observar que também será criado um modelo simples, composto apenas por constantes sazonais e estimado por Mínimos Quadrados Ordinários, com o objetivo de verificar sua aderência e performance frente aos modelos mais complexos.

*Tabela 3.3: Relação dos modelos estimados*

Modelo	Nome do modelo	Técnica	Descrição	Ótica	Pesos das Componentes
1	PIB_A_CDS	<i>Autometrics</i>	Projeção direta com <i>dummies</i> de saturação	-	-
2	PIB_A_SDS	<i>Autometrics</i>	Projeção direta sem <i>dummies</i> de saturação	-	-
3	PIB_A_MS	<i>Markov-Switching</i>	Projeção direta	-	-
4	PIB_A_ES_LN	Espaço-Estado	Projeção direta no logaritmo natural do nível	-	-
5	PIB_A_ES_DL	Espaço-Estado	Projeção direta	-	-
6	PIB_DO_FM_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N1)	Fixos (média)
7	PIB_DO_FT_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N1)	Fixos (trimestre)
8	PIB_DO_FM_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N2)	Fixos (média)
9	PIB_DO_FT_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N2)	Fixos (trimestre)
10	PIB_DD_FM_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N1)	Fixos (média)
11	PIB_DD_FT_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N1)	Fixos (trimestre)
12	PIB_DD_FM_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N2)	Fixos (média)
13	PIB_DD_FT_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N2)	Fixos (trimestre)
14	PIB_DO_ES_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N1)	Estocásticos
15	PIB_DO_ES_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Oferta (N2)	Estocásticos
16	PIB_DD_ES_N1	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N1)	Estocásticos
17	PIB_DD_ES_N2	<i>Autometrics</i>	Agregação das projeções das componentes	Demanda (N2)	Estocásticos
18	PIB_VO_N1	<i>Autometrics</i>	VAR com agregado e desagregações	Oferta (N1)	-
19	PIB_VD_N1	<i>Autometrics</i>	VAR com agregado e desagregações	Demanda (N1)	-
20	PIB_CZ	MQO	Projeção direta apenas com constantes sazonais	-	-

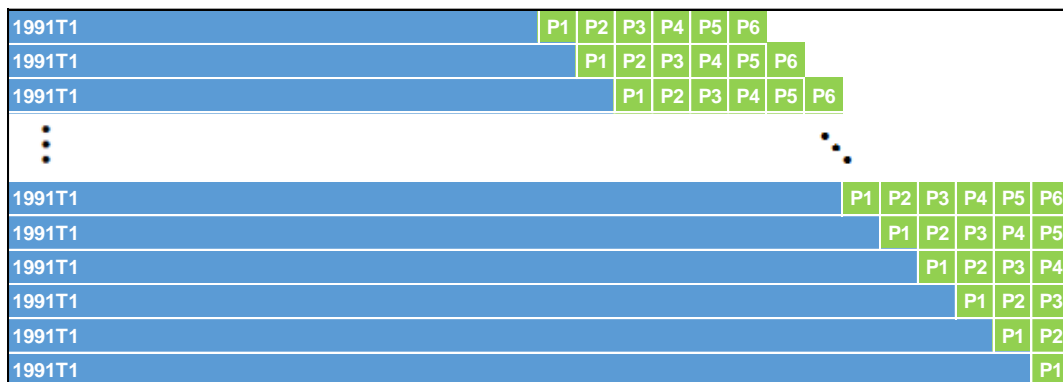
Fonte: elaboração própria.

Nota: Os modelos são estimados na primeira diferença do logaritmo natural da variável, exceto quando especificado.

## 4 RESULTADOS

A construção das projeções para o indicador agregado, séries desagregadas e pesos das componentes fora da amostra de construção dos modelos foi realizada até seis trimestres à frente em uma primeira simulação, iniciando no primeiro trimestre de 2008 e encerrando no segundo trimestre de 2014. A cada nova informação adicionada, os modelos foram estimados novamente com o objetivo de se obter a melhor aproximação levando em consideração o novo ponto de dados, mantendo-se fixo o período inicial no primeiro trimestre de 1991. A Figura 4.1 abaixo esquematiza visualmente a realização da rotina de atualização dos modelos.

*Figura 4.1: Exemplo da dinâmica de modelagem e projeção utilizada*



Legenda:



Base de Modelagem



Projeções (de 1 a 6 passos à frente)

Fonte: elaboração própria

Para as estimativas da série agregada, das componentes, bem como seus respectivos pesos, foram realizados os devidos cálculos para retornar as informações aos valores em nível, somando a diferença do logaritmo natural projetada ao valor logaritmizado do período anterior, e depois exponenciando o resultado para retornar a série ao padrão original. Vale ressaltar que as únicas exceções a este procedimento são as projeções do modelo estrutural do logaritmo do indicador agregado, no qual apenas a exponenciação foi calculada. A construção das estimativas do PIB agregado pelas informações desagregadas foi realizada utilizando a ponderação mencionada na seção anterior.

De acordo com o passo da projeção, a amostra submetida à avaliação do MCS terá um tamanho diferente ao se travar a base de dados no último ponto no qual exista a informação divulgada. Assim, caso uma projeção seja de um período no qual não exista o valor observado, isto é, posterior ao segundo trimestre de 2014, a mesma não será submetida ao MCS. Desta forma, a amostra para as projeções um passo à frente contém 26 observações, enquanto que para seis passos à frente a amostra contém 21 estimativas para cada modelo.

A Tabela 4.2 disponibilizada abaixo mostra os resultados da raiz do EQM aplicado para todos os modelos com projeções até 6 passos à frente.

*Tabela 4.2: Raiz do EQM da Simulação 1*

Modelo	Nome do Modelo	Horizonte de Projeção					
		1	2	3	4	5	6
1	PIB_A_CDS	2,66	<u>3,76</u>	<u>4,20</u>	<u>4,22</u>	<u>3,94</u>	<u>4,18</u>
2	PIB_A_SDS	2,54	<u>3,82</u>	<u>4,18</u>	<u>4,05</u>	<u>3,98</u>	<u>4,17</u>
3	PIB_A_MS	3,73	5,32	6,13	6,55	7,42	7,16
4	PIB_A_ES_LN	2,90	4,23	5,98	6,80	7,77	7,98
5	PIB_A_ES_DL	2,60	3,98	4,91	5,27	5,02	5,10
6	PIB_DO_FM_N1	<u>2,41</u>	3,94	4,90	5,65	6,12	6,71
7	PIB_DO_FT_N1	2,54	4,27	5,45	6,44	7,00	7,73
8	PIB_DO_FM_N2	<u>2,39</u>	3,97	5,06	5,84	6,16	6,62
9	PIB_DO_FT_N2	2,52	4,31	5,61	6,62	7,07	7,72
10	PIB_DD_FM_N1	2,92	3,91	5,14	4,89	<u>4,98</u>	<u>4,98</u>
11	PIB_DD_FT_N1	3,00	4,07	5,54	5,44	5,50	5,51
12	PIB_DD_FM_N2	3,12	4,31	5,63	5,50	5,79	6,25
13	PIB_DD_FT_N2	3,28	4,63	6,26	6,42	6,85	7,32
14	PIB_DO_ES_N1	2,49	4,19	5,39	6,36	6,94	7,68
15	PIB_DO_ES_N2	2,49	4,22	5,54	6,55	7,01	7,62
16	PIB_DD_ES_N1	2,82	3,84	5,29	5,12	5,14	5,10
17	PIB_DD_ES_N2	3,11	4,37	6,01	6,12	6,53	6,96
18	PIB_VO_N1	<u>2,42</u>	<u>3,74</u>	4,61	5,21	5,58	5,56
19	PIB_VD_N1	2,62	3,90	4,55	5,09	5,33	5,55
20	PIB_CZ	2,75	4,00	<u>4,48</u>	<u>4,79</u>	5,31	5,55

Fonte: elaboração própria.


Nota: Os três modelos com a menor raiz do EQM para cada horizonte de projeção estão sublinhados.

A partir das informações da raiz do Erro Quadrático Médio, observa-se em uma análise inicial que não existe um modelo que possua melhor desempenho em todos os horizontes de projeção. Considerando as estimativas 1 passo à frente, os modelos que se destacaram foram aqueles que utilizam informações desagregadas da ótica da oferta, sendo dois deles formados pelas projeções univariadas com

pesos igual à média do ano anterior, e o terceiro o modelo VAR no primeiro nível de desagregação. Nas projeções 2 passos à frente, o mesmo modelo VAR possui melhor performance, seguido pelos modelos agregados estimados via Autometrics. Para os passos 3 e 4, os dois melhores modelos são os agregados com e sem constantes sazonais, seguido pelo modelo construído apenas com constantes sazonais via MQO. Por fim, nos passos 5 e 6 as estimativas agregadas se mantêm, e o modelo mais ingênuo é substituído pelo modelo formado pelas informações desagregadas da ótica da demanda com peso fixos. Assim, verifica-se que para as projeções de horizonte mais curto os modelos desagregados fornecem melhores aproximações, enquanto para períodos mais extensos os modelos do indicador agregado são mais consistentes.

Na Figura 4.2, constata-se que não existe nenhum modelo que esteja sistematicamente com o pior desempenho. Para os primeiros três horizontes de projeção, o modelo de *Markov-Switching* obteve um baixo desempenho, sendo superado pelo modelo estrutural para o logaritmo do PIB nos três últimos pontos. No geral, nota-se que a magnitude do EQM cresce mais devagar conforme o período de estimativa aumenta. Para os modelos univariados da série agregada com melhor desempenho, as curvas chegam a estabilizar.

Figura 4.2: Raiz do EQM por horizonte de projeção da Simulação 1



Fonte: elaboração própria

Nota: A partir da décima primeira série, o padrão de cores se repete, mas a linha passa a ser tracejada.

Contudo, vale ressaltar que apenas a análise do EQM não fornece fundamentação estatística com relação às diferenças de desempenho entre os diferentes modelos, nem indicações de que os dados são suficientes para que a amostra seja informativa. Desta forma, a utilização do *Model Confidence Set* garante que estas duas incertezas sejam esclarecidas estatisticamente. Na Tabela 4.3 se encontram os resultados da aplicação do algoritmo em todos os modelos estimados, e a seleção de melhores modelos com 90% de probabilidade estão indicados com um asterisco ao lado do MCS p-valor. Interessante notar que o processamento também indica quais modelos seriam acrescentados ao conjunto caso a probabilidade fosse flexibilizada para 75%. O MCS p-valor destes modelos estão marcados com dois asteriscos.

*Tabela 4.3: MCS p-valor da Simulação 1*

Modelo	Nome do Modelo	Horizonte de Projeção					
		1	2	3	4	5	6
1	PIB_A_CDS	0.1430 **	0.9504 *	0.7928 *	0.4628 *	1.0000 *	0.9664 *
2	PIB_A_SDS	0.3822 *	0.9504 *	1.0000 *	1.0000 *	0.8151 *	1.0000 *
3	PIB_A_MS	0.0252	0.1885 **	0.0313	0.0016	0.0000	0.0008
4	PIB_A_ES_LN	0.1403 **	0.6233 *	0.0515	0.0265	0.0210	0.0164
5	PIB_A_ES_DL	0.1430 **	0.8102 *	0.1917 **	0.0510	0.0859	0.2801 *
6	PIB_DO_FM_N1	0.9048 *	0.8313 *	0.2083 *	0.0265	0.0210	0.0096
7	PIB_DO_FT_N1	0.1430 **	0.4929 *	0.0515	0.0021	0.0002	0.0002
8	PIB_DO_FM_N2	1.0000 *	0.8102 *	0.1917 **	0.0265	0.0210	0.0543
9	PIB_DO_FT_N2	0.1472 **	0.5943 *	0.0515	0.0096	0.0064	0.0077
10	PIB_DD_FM_N1	0.1403 **	0.8982 *	0.1140 **	0.1205 **	0.1053 **	0.3637 *
11	PIB_DD_FT_N1	0.1403 **	0.6277 *	0.0383	0.0265	0.0210	0.2126 *
12	PIB_DD_FM_N2	0.1394 **	0.4929 *	0.0411	0.0265	0.0210	0.0077
13	PIB_DD_FT_N2	0.0952	0.3648 *	0.0204	0.0012	0.0000	0.0001
14	PIB_DO_ES_N1	0.6717 *	0.5943 *	0.0515	0.0035	0.0007	0.0004
15	PIB_DO_ES_N2	0.4383 *	0.5943 *	0.0515	0.0021	0.0021	0.0008
16	PIB_DD_ES_N1	0.1403 **	0.9504 *	0.0735	0.1117 **	0.0835	0.2801 *
17	PIB_DD_ES_N2	0.1184 **	0.4471 *	0.0253	0.0014	0.0000	0.0008
18	PIB_VO_N1	0.9048 *	1.0000 *	0.4611 *	0.0694	0.0210	0.1925 **
19	PIB_VD_N1	0.1430 **	0.8897 *	0.4721 *	0.1117 **	0.0859	0.2801 *
20	PIB_CZ	0.1430 **	0.7396 *	0.4721 *	0.1117 **	0.0835	0.2333 *

Fonte: elaboração própria.

Nota: \* - modelos que pertencem ao MCS com 90% de probabilidade

\*\* - modelos que pertencem ao MCS com 75% de probabilidade

Analisando os resultados, verifica-se que não existem ganhos significativos na utilização de modelos desagregados para estimar o indicador agregado. Os únicos modelos a constarem dentro dos conjuntos  $\check{C}_{90\%}$  e  $\check{C}_{75\%}$  em todos os passos são os

modelos da série agregada estimado pelo *Autometrics* com e sem *dummies* de saturação, e o modelo dos indicadores desagregados pela ótica da demanda com pesos fixos à média do ano anterior. Também não foi verificada a ocorrência de apenas um único modelo pertencente à  $C^*$  para nenhum dos horizontes de projeção, indicado que não existe uma dominância de determinada técnica sobre as demais para os dados PIB trimestral coletados para a realização deste trabalho.

Para os dois primeiros horizontes, nota-se que quase todas as projeções pertencem aos grupos  $\check{C}_{90\%}$  e  $\check{C}_{75\%}$ , dos quais no passo 2 a estimativa realizada por *Markov-Switching* é a única que não consta em  $\check{C}_{90\%}$ . No passo 3, os modelos VAR são mantidos nos conjuntos, assim como modelo desagregado pela ótica da oferta no primeiro nível com peso fixo à média. Nos horizontes de projeção de 4 e 5 passos à frente, nota-se o desempenho superior dos modelos do indicador agregado. No passo 6, os modelos desagregados pela ótica da demanda com peso fixo voltam a fazer parte de  $\check{C}_{90\%}$ , assim como o modelo estrutural sem inclinação da série agregada. De modo geral, a contribuição dos modelos desagregados não foi significativa. Os resultados sugerem que os erros associados às dinâmicas mais irregulares do comportamento das componentes prejudica a medida do indicador agregado, e a adesão de pesos estocásticos potencializa ainda mais este efeito.

Analisando os p-valores do MCS, pode-se notar que o modelo com pior desempenho dentre todos os competidores foi o *Markov-Switching*, seguido pelo modelo desagregado pela ótica da demanda no segundo nível, com pesos fixos ao mesmo trimestre do ano anterior. A inclusão destes modelos no MCS no passo horizonte de projeção 2 passos à frente é um indicativo de que a base de dados não é informativa para os primeiros horizontes de projeção. Desta forma, foi realizada uma segunda simulação de projeções para analisar a performance dos modelos em um período de observação mais longo, com o cálculo das estimativas iniciando a partir do primeiro trimestre de 2000, projetando até 6 passos à frente, utilizando o mesmo procedimento de reestimar os modelos a cada nova observação disponível (Figura 4.1). Para 1 trimestre à frente, foram contabilizadas 58 projeções, ao passo que para o horizonte de 6 trimestres a base contém 53 observações. Os modelos VAR foram os únicos modelos nos quais não foi possível realizar as projeções com

as mesmas especificações do processamento anterior, dado que o período de informações é insuficiente frente a quantidade de parâmetros a serem estimados pelo *Autometrics*. A Tabela 4.4 contém os valores da raiz do EQM calculados sobre as projeções da segunda base de dados.

*Tabela 4.4: Raiz do EQM da Simulação 2*

Modelo	Nome do Modelo	Horizonte de Projeção					
		1	2	3	4	5	6
1	PIB_A_CDS	2,19	3,15	<u>3,59</u>	<u>3,91</u>	<u>4,11</u>	<u>4,45</u>
2	PIB_A_SDS	2,11	3,19	<u>3,51</u>	<u>3,68</u>	<u>4,05</u>	<u>4,40</u>
3	PIB_A_MS	2,98	4,17	4,65	4,40	5,05	5,71
4	PIB_A_ES_LN	2,60	3,59	4,91	5,60	6,70	7,22
5	PIB_A_ES_DL	2,13	3,29	3,92	4,26	4,58	5,04
6	PIB_DO_FM_N1	<u>1,93</u>	<u>2,98</u>	<u>3,62</u>	4,09	<u>4,50</u>	4,95
7	PIB_DO_FT_N1	2,02	3,18	3,94	4,53	5,01	5,57
8	PIB_DO_FM_N2	<u>1,88</u>	<u>2,94</u>	3,70	4,25	4,50	<u>4,81</u>
9	PIB_DO_FT_N2	1,98	3,17	4,06	4,73	5,09	5,60
10	PIB_DD_FM_N1	2,67	3,58	4,27	4,32	4,98	5,31
11	PIB_DD_FT_N1	2,72	3,63	4,43	4,46	5,00	5,20
12	PIB_DD_FM_N2	2,72	3,70	4,40	4,48	5,04	5,64
13	PIB_DD_FT_N2	2,79	3,75	4,62	4,75	5,25	5,65
14	PIB_DO_ES_N1	1,99	3,15	3,90	4,48	4,94	5,51
15	PIB_DO_ES_N2	<u>1,96</u>	<u>3,13</u>	4,00	4,65	4,97	5,40
16	PIB_DD_ES_N1	2,63	3,58	4,35	4,39	5,02	5,38
17	PIB_DD_ES_N2	2,72	3,70	4,52	4,64	5,22	5,81
20	PIB_CZ	2,62	3,80	3,89	<u>3,91</u>	4,65	5,22


Fonte: elaboração própria.

Nota: Os três modelos com a menor raiz do EQM para cada horizonte de projeção estão sublinhados.

Nas projeções de 1 e 2 passos à frente, os modelos desagregados são aqueles que possuem os menores EQM, diferentemente do observado na Tabela 4.2, na qual a partir do passo 2 os modelos agregados estimados pelo *Autometrics* já apresentavam valores menores. Para os horizontes de projeção restantes, as estimativas univariadas do indicador agregado são aquelas com maior destaque, resultado semelhante ao encontrado na primeira simulação. Na Figura 4.3, nota-se que as curvas dos EQM se encontram menos espaçadas, com exceção do modelo estrutural para o nível, o que indica uma maior equivalência entre a aplicação das diversas técnicas na tentativa de estimar o nível do PIB trimestral brasileiro. No entanto, estas constatações não são suportadas estatisticamente, sendo novamente necessária a utilização do *Model Confidence Set*.



Figura 2.3: Raiz do EQM por horizonte de projeção da Simulação 2



A análise dos resultados do MCS aplicados na segunda simulação apresentados na Tabela 4.5 sugerem que os modelos desagregados são melhores nos horizontes de projeção mais curtos, de 1 e 2 passos à frente, diferentemente do verificado na simulação anterior, na qual uma grande quantidade de modelos foi mantida nos conjuntos  $\check{C}_{90\%}$  e  $\check{C}_{75\%}$ , o que constata que amostra utilizada previamente não era suficientemente informativa para assegurar uma distinção entre a performance dos modelos. Para os horizontes restantes, os modelos univariados passam a ser melhores classificados, com destaque para o modelo estimado pelo *Autometrics* sem constantes sazonais. Os modelos agregados de *Markov-Switching* e estrutural no nível continuaram a não apresentar boas aproximações.

Outra diferença com relação à primeira simulação se dá nas projeções provenientes dos modelos com informações das componentes, as quais conseguem se manter nos grupos finais após a aplicação do MCS, com exceção da estimativa com pesos estocásticos na ótica da demanda no segundo nível, que não foi selecionada para nenhum conjunto. O único modelo que se manteve em  $\check{C}_{90\%}$  em todos os horizontes de projeção foi aquele formado pelas séries desagregadas na ótica da oferta, no segundo nível de detalhamento, e com pesos fixos à média. Vale ressaltar que, para os horizontes de projeção mais longos, a quantidade de modelos

selecionada é maior, o que indica que para prazos mais longos as diferentes técnicas produzem resultados mais próximos. No entanto, o comportamento mais errático das séries desagregadas e de seus respectivos pesos ainda é um fator de perda de aderência nas estimativas do agregado, se comparadas com as projeções univariadas pelo *Autometrics*. Outro ponto a salientar é com relação ao desempenho do modelo apenas com constantes sazonais, que a partir do passo 3 se mantém nos conjuntos de melhores modelos, o que indica uma maior previsibilidade do comportamento da série agregada somente na dinâmica da sazonalidade, o que também pode influenciar na maior eficiência dos modelos univariados para estimar o PIB trimestral brasileiro.

*Tabela 4.5: MCS p-valor da Simulação 2*

Modelo	Nome do Modelo	Horizonte de Projeção					
		1	2	3	4	5	6
1	PIB_A_CDS	0.0001	0.5824 *	0.7808 *	0.2138 *	0.6122 *	0.7354 *
2	PIB_A_SDS	0.0075	0.0901	1.0000 *	1.0000 *	1.0000 *	1.0000 *
3	PIB_A_MS	0.0000	0.0297	0.0605	0.0963	0.1451 **	0.0909
4	PIB_A_ES_LN	0.0001	0.0526	0.0760	0.0665	0.0403	0.0435
5	PIB_A_ES_DL	0.0007	0.0526	0.3969 *	0.1138 **	0.3766 *	0.3718 *
6	PIB_DO_FM_N1	0.4274 *	0.6877 *	0.7808 *	0.2138 *	0.4757 *	0.5724 *
7	PIB_DO_FT_N1	0.1141 **	0.0526	0.3969 *	0.0963	0.1861 **	0.1123 **
8	PIB_DO_FM_N2	1.0000 *	1.0000 *	0.7808 *	0.2138 *	0.4757 *	0.5724 *
9	PIB_DO_FT_N2	0.1141 **	0.0901	0.0760	0.0928	0.1200 **	0.1128 **
10	PIB_DD_FM_N1	0.0000	0.0526	0.0760	0.1138 **	0.1861 **	0.1443 **
11	PIB_DD_FT_N1	0.0000	0.0526	0.0605	0.0928	0.0970	0.2436 *
12	PIB_DD_FM_N2	0.0000	0.0526	0.0760	0.0928	0.0854	0.0836
13	PIB_DD_FT_N2	0.0000	0.0487	0.0498	0.0665	0.0785	0.0909
14	PIB_DO_ES_N1	0.1141 **	0.0526	0.5147 *	0.1138 **	0.2921 *	0.1128 **
15	PIB_DO_ES_N2	0.1141 **	0.2069 *	0.1566 **	0.0928	0.3025 *	0.1960 **
16	PIB_DD_ES_N1	0.0000	0.0526	0.0760	0.0963	0.1200 **	0.1141 **
17	PIB_DD_ES_N2	0.0000	0.0487	0.0561	0.0879	0.0786	0.0792
20	PIB_CZ	0.0000	0.0496	0.5147 *	0.3551 *	0.3149 *	0.1960 **

Fonte: elaboração própria.

Nota: \* - modelos que pertencem ao MCS com 90% de probabilidade

\*\* - modelos que pertencem ao MCS com 75% de probabilidade

## 5 CONCLUSÃO

Este trabalho teve como objetivo analisar se existem ganhos nas projeções considerando os dados desagregados para o PIB trimestral brasileiro de 1991 até a metade de 2014, através da aplicação de pesos fixos e estocásticos. Diversas técnicas de modelagem de séries temporais lineares e não lineares foram utilizadas para a construção de modelos a partir da informação agregada e desagregada, e o procedimento de comparação das estimativas definido foi o *Model Confidence Set*, com o propósito de estabelecer uma fundamentação estatística na avaliação do conjunto de melhores projeções para os dados coletados.

Após todas as análises realizadas com os resultados das simulações, obteve-se empiricamente a indicação de que a aplicação da desagregação para o PIB trimestral brasileiro se mostra satisfatória apenas nas projeções de um e dois passos à frente, pela ótica da oferta e com pesos fixos. Para os períodos restantes, as projeções realizadas diretamente para o indicador agregado de modelos gerados através de seleção automática são as que melhor se aproximam do resultado real. A opção de ponderação com pesos variantes no tempo não ajuda a melhorar as estimativas, e as técnicas univariadas não lineares apresentaram as piores performances dentro da coleção de projeções. A utilização de modelos multivariados não apresentou vantagens significativas na qualidade das projeções, e não foi possível estimar as equações para uma amostra de modelagem com menos dados, devido à maior quantidade de parâmetros a serem calculados. A janela de estimação, bem como o período no qual se deseja estimar os indicadores, também desempenha papel relevante, uma vez que ao considerar as projeções a partir do primeiro trimestre de 2008, época na qual deflagrou-se uma crise econômica mundial, os dados históricos não foram informativos o suficiente para produzir resultados nos quais sinalizassem os melhores modelos no curto prazo.

O presente trabalho procurou contribuir para a literatura ao abordar diversas metodologias de projeção para o PIB trimestral brasileiro, não se limitando aos modelos aplicados diretamente na série agregada. Um dos fatores que limitaram este estudo foi a disponibilidade das informações, as quais cobrem um período histórico relativamente curto. Existem algumas séries das Contas Nacionais

Trimestrais que iniciam em 1980, porém a maioria passou a ser calculada e divulgada oficialmente pelo IBGE tendo o primeiro trimestre de 1991 como ponto inicial. Assim, perdem-se cerca de 10 anos de dados que poderiam contribuir de forma contundente para resultados mais robustos. Outro ponto que vale ser mencionado é com relação à ausência das informações desagregadas sob a ótica da renda, as quais poderiam ser utilizadas para um maior enriquecimento da análise da performance das projeções de dados desagregados.

Como possível extensão a este trabalho, sugere-se realizar as estimativas das componentes e dos pesos estocásticos por modelos VAR utilizando o *Autometrics*, e depois realizar as devidas ponderações para obter o indicador agregado, como indicado Brüggemann e Lütkepohl (2013). É evidente que existirão limitações com relação ao nível de desagregação, porém são mais modelos candidatos à avaliação comparativa de suas performances frente as projeções da lista de modelos aqui desenvolvida. A estimativa dos índices desagregados e pesos pelas técnicas de *Markov-Switching* e modelos estruturais de espaço-estado também é uma alternativa válida, porém trabalhosa devido a quantidade de cálculos e processamentos a serem realizados. Outra indicação de pesquisa futura envolve incorporar projeções de modelos de fatores utilizando outras variáveis macroeconômicas além das disponíveis no Sistema de Contas Nacionais, como inflação, taxa de desemprego, estrutura a termo da taxa de juros, entre outras. A adição de informações que capturam outras dinâmicas, particularidades e nuances da economia podem ter o potencial de oferecer estimativas tão ou mais acuradas do que aquelas encontradas neste trabalho para o PIB trimestral brasileiro.


Uma outra vertente de estudos dentro da econometria que pode ser aplicada como ampliação da análise deste trabalho é a combinação de projeções. Cada metodologia de modelagem é afetada de forma diferente por fenômenos diversos na dinâmica das séries, como choques ou quebras estruturais, e assim o comportamento do modelo pode ser tanto de rápida identificação e adaptação a determinadas condições, quanto de dificuldade em captar outras particularidades presentes nas observações estudadas. Assim, a eficiência da projeção pode não ser ótima caso se considere apenas um modelo para representar os dados de interesse. Similarmente ao argumento de diversificação de ações para redução do risco de

uma carteira de investimentos, a estratégia de combinar projeções de diferentes modelos pode ser relevante na estimação de variáveis econômicas por resultar em menores erros de aproximação, garantindo uma maior confiabilidade no entendimento da informação estudada.


## APÊNDICE A - GRÁFICOS DAS SÉRIES UTILIZADAS

### A.1 SÉRIES ENCADEADAS

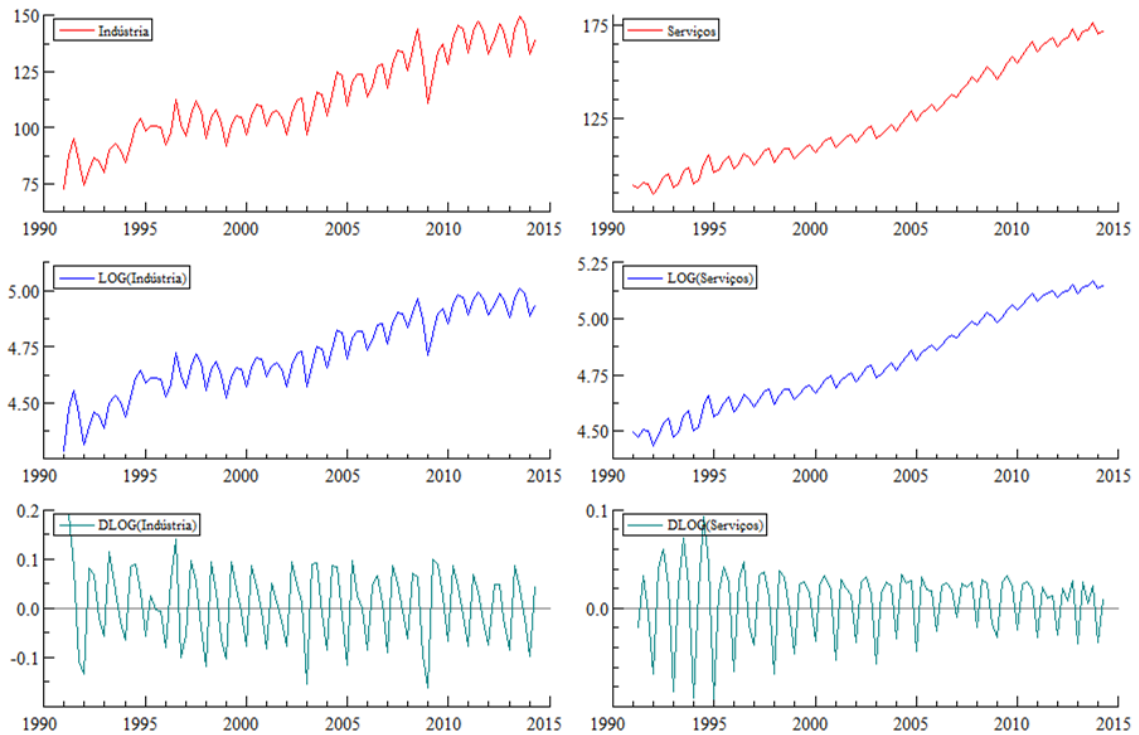
#### PIB (Produto Interno Bruto)



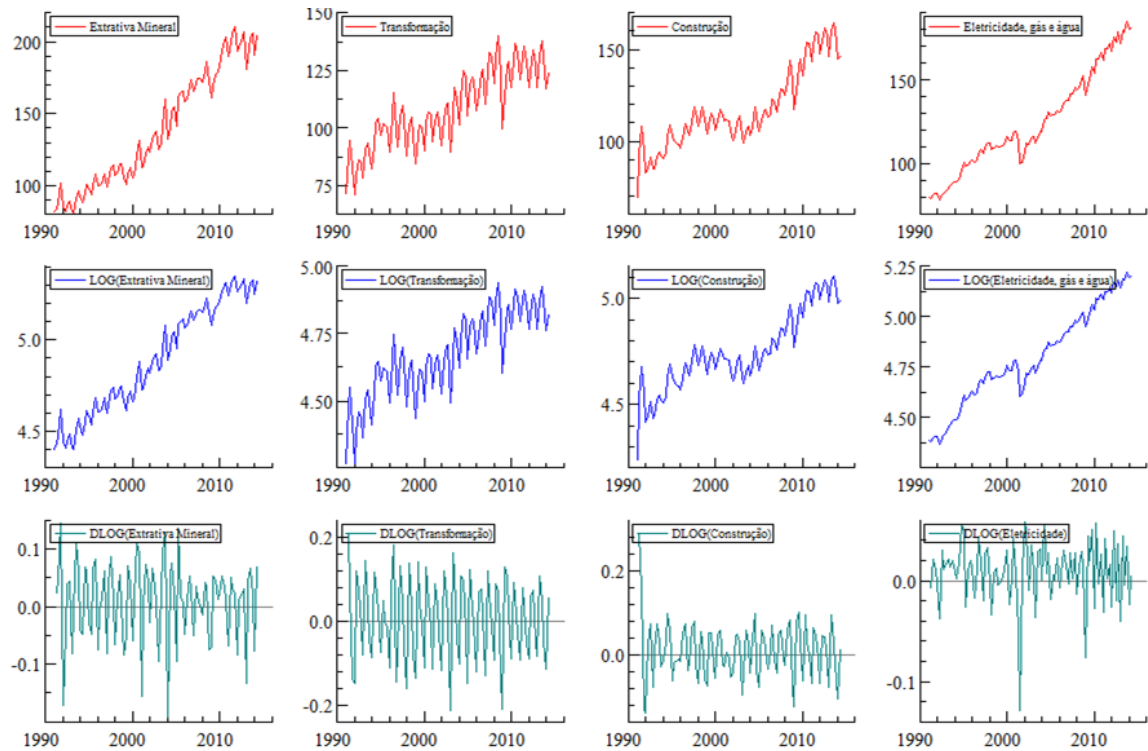
#### Ótica da oferta (N1): Impostos e Agropecuária



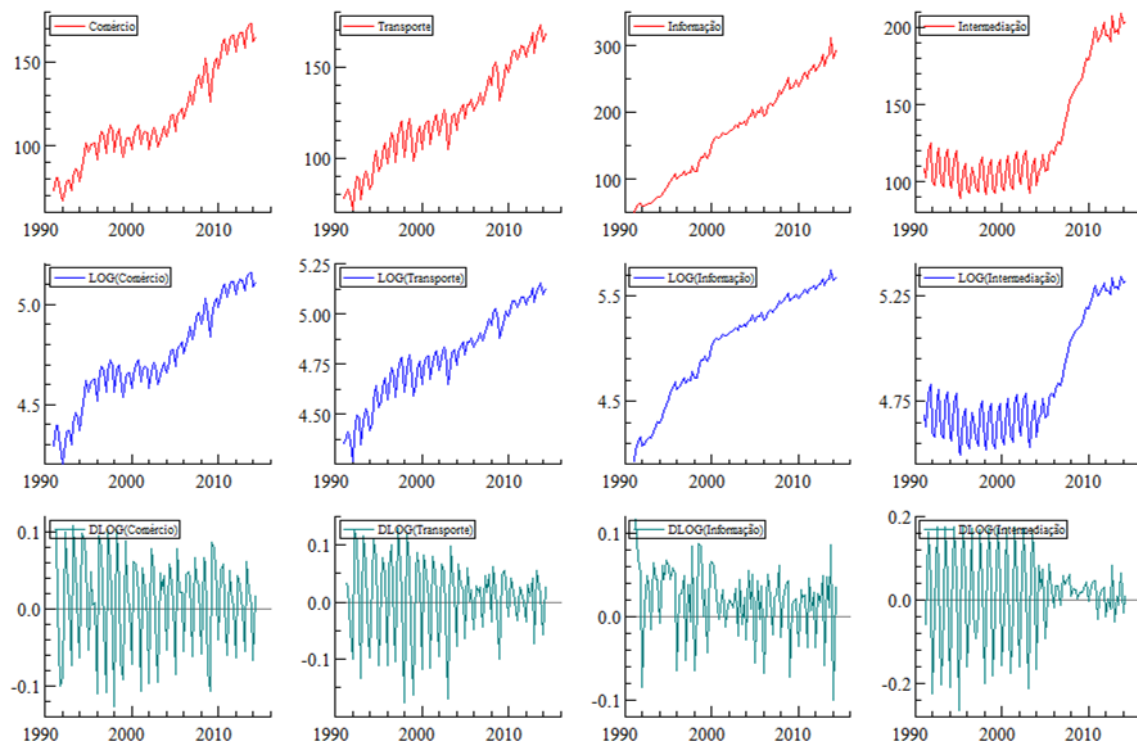
### Ótica da oferta (N1): Indústria e Serviços



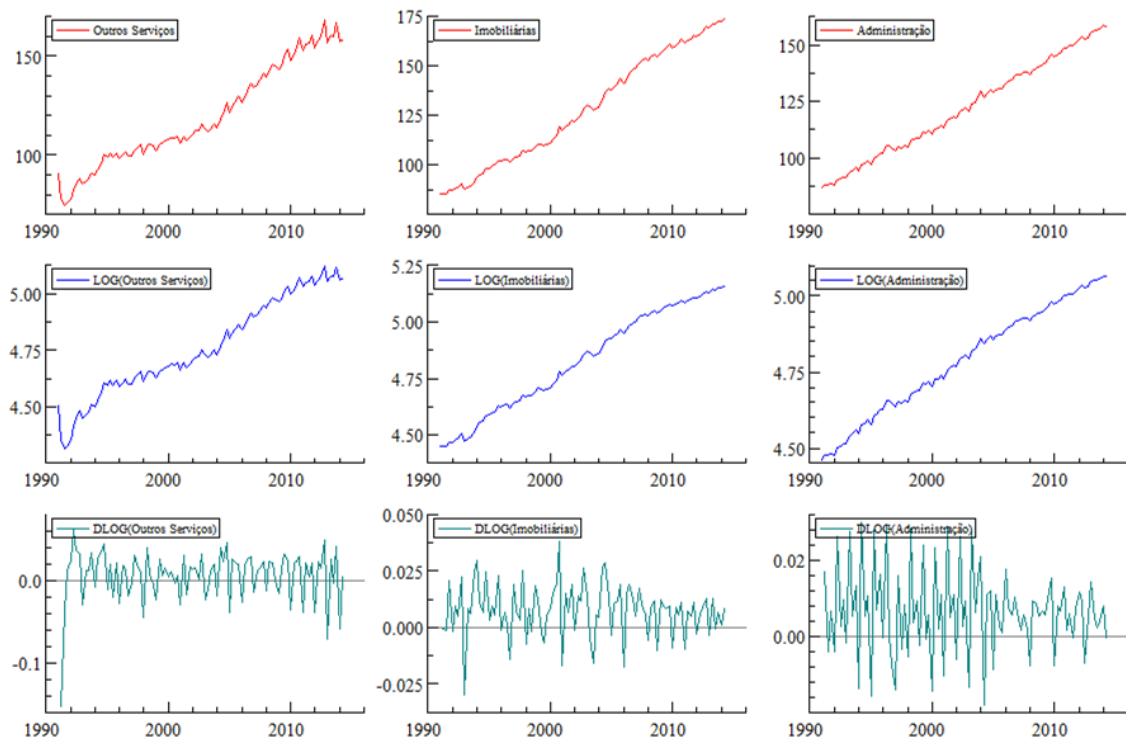
### Ótica da oferta (N2) – Indústrias: Extrativa Mineral, Transformação, Construção e Eletricidade, gás e água.



## Ótica da oferta (N2) – Serviços: Comércio, Transporte, Informação e Intermediação Financeira

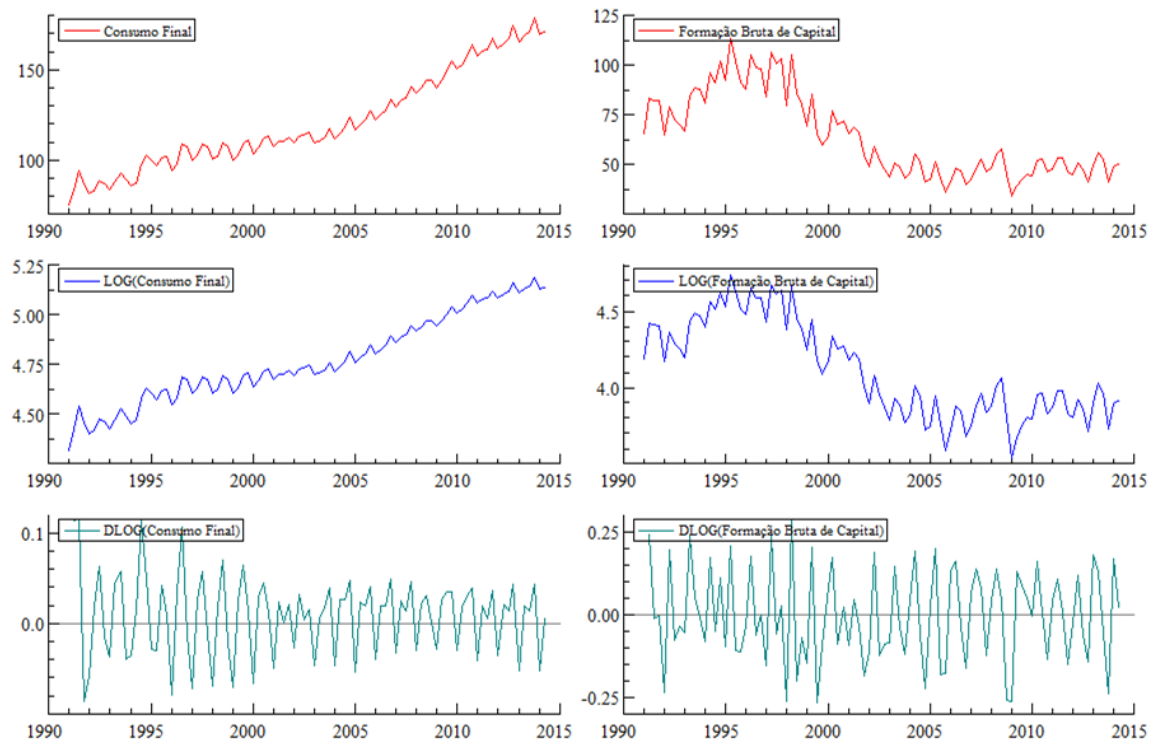


## Ótica da oferta (N2) – Serviços: Outros Serviços, Imobiliárias e Administração





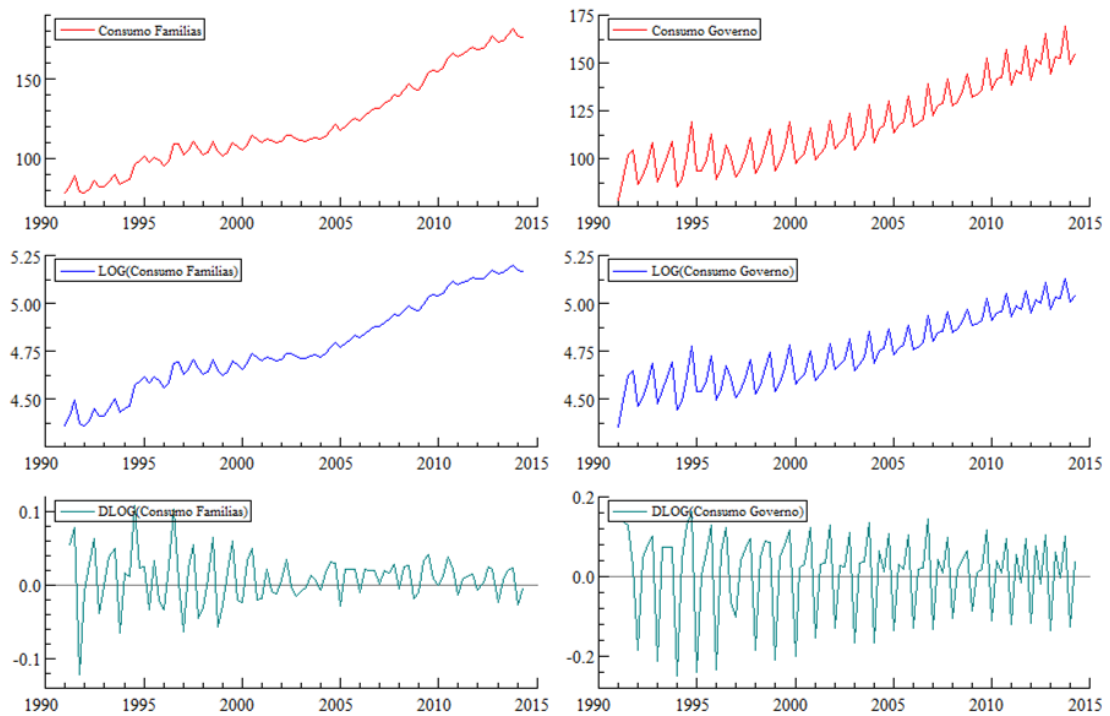
### Ótica da demanda (N1): Consumo Final, Formação Bruta de Capital



### Ótica da demanda (N1): Exportações e Importações

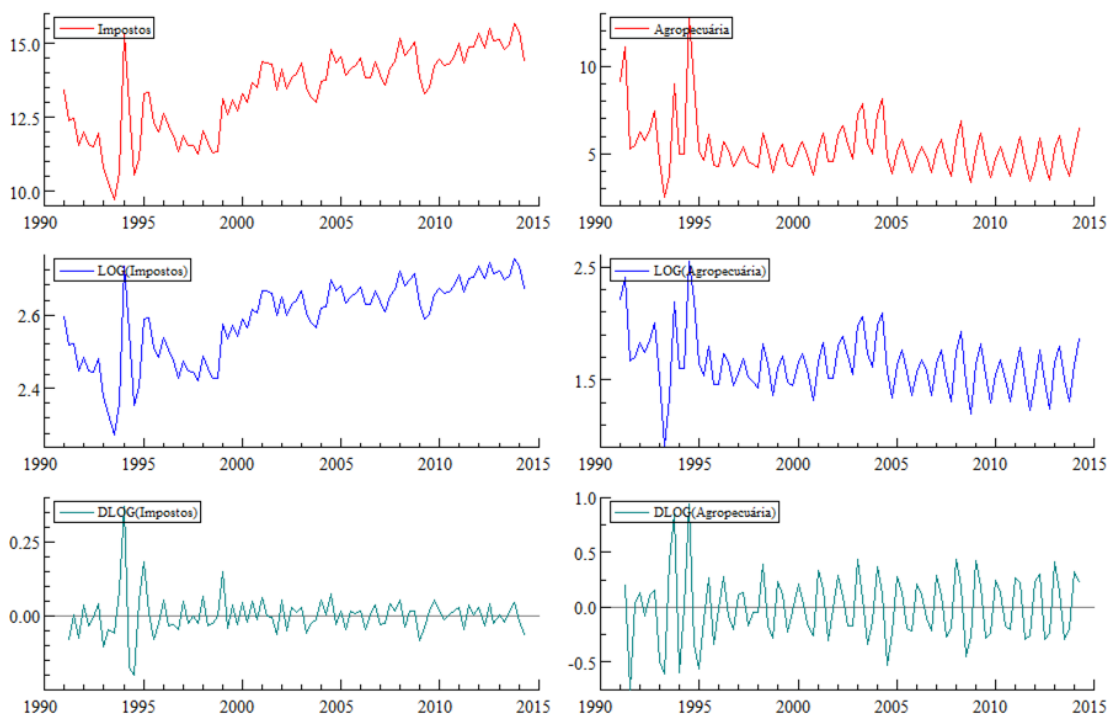


## Ótica da demanda (N2) – Consumo: Famílias e Governo



## A.2 PESOS (VALORES CORRENTES)

### Ótica da oferta (N1): Impostos e Agropecuária

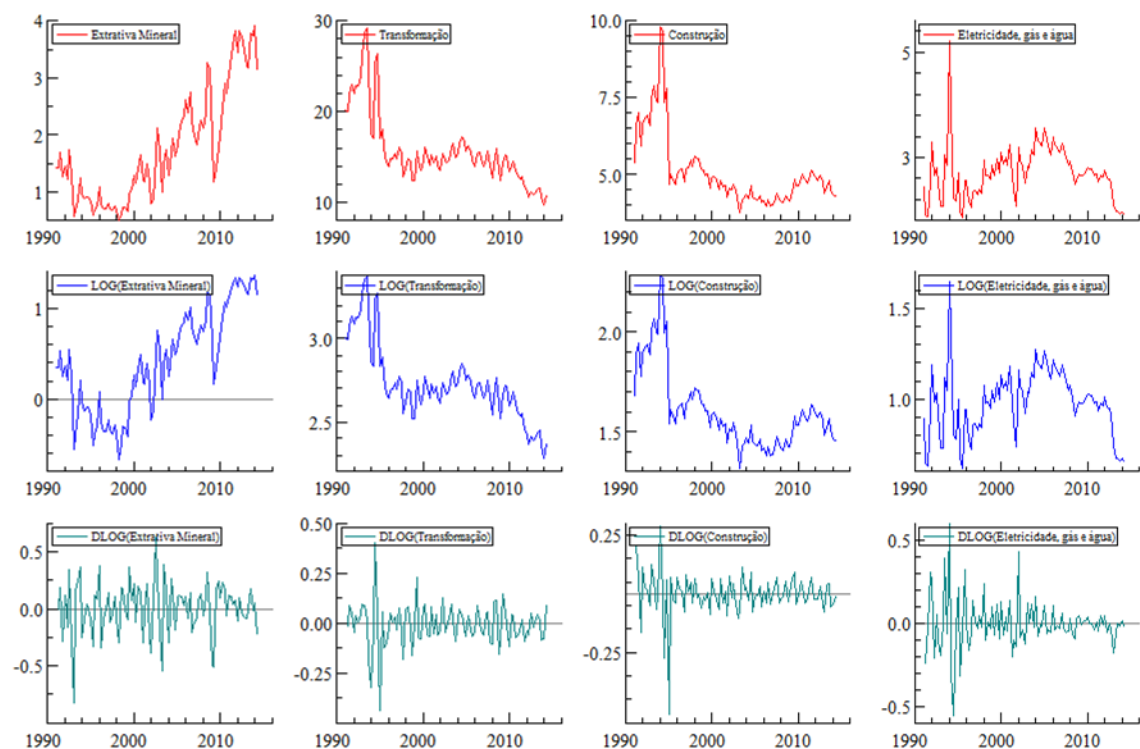


Observação: Para o período de 1994T1, o peso original do indicador de Agropecuária é negativo. Assim, o mesmo foi substituído pela média dos pesos do ano anterior (1993).

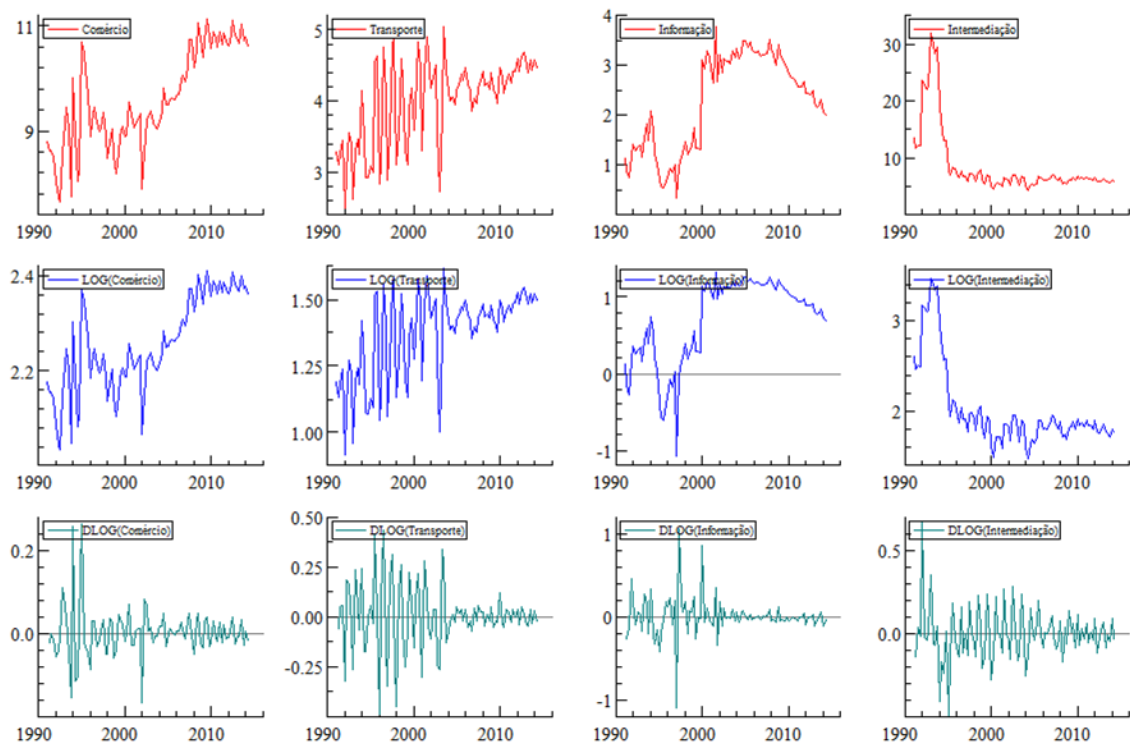
### Ótica da oferta (N1): Indústria e Serviços



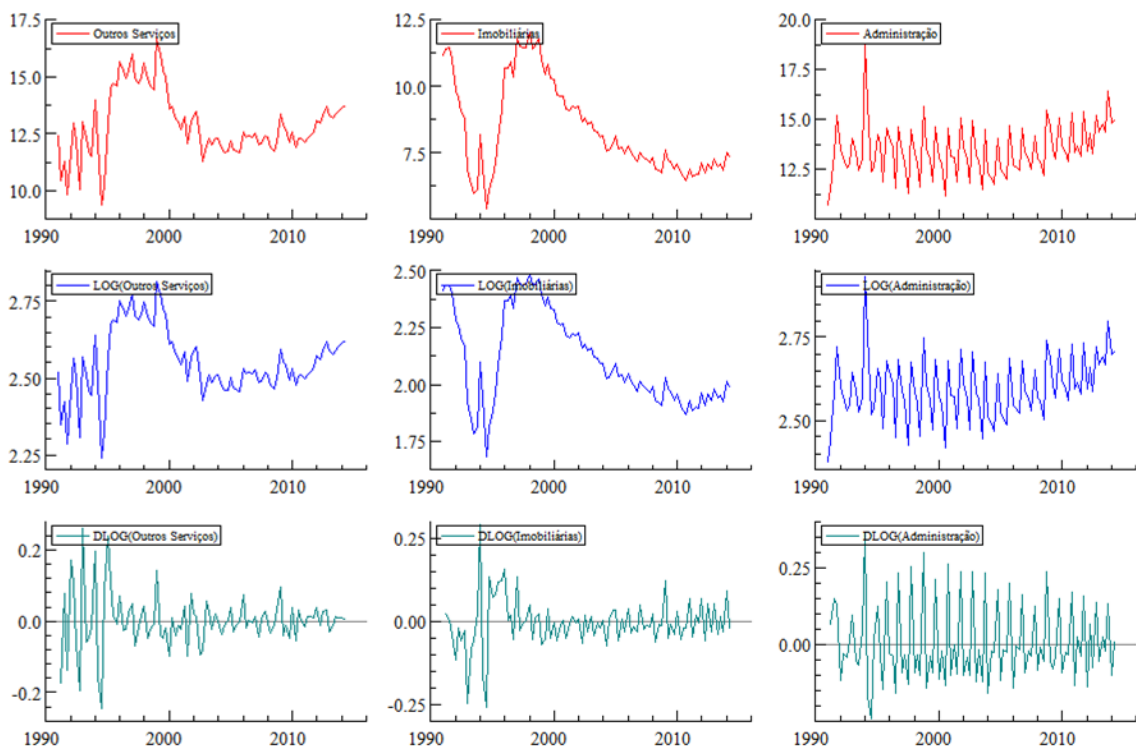
### Ótica da oferta (N2) – Indústrias: Extrativa Mineral, Transformação, Construção e Eletricidade, gás e água.



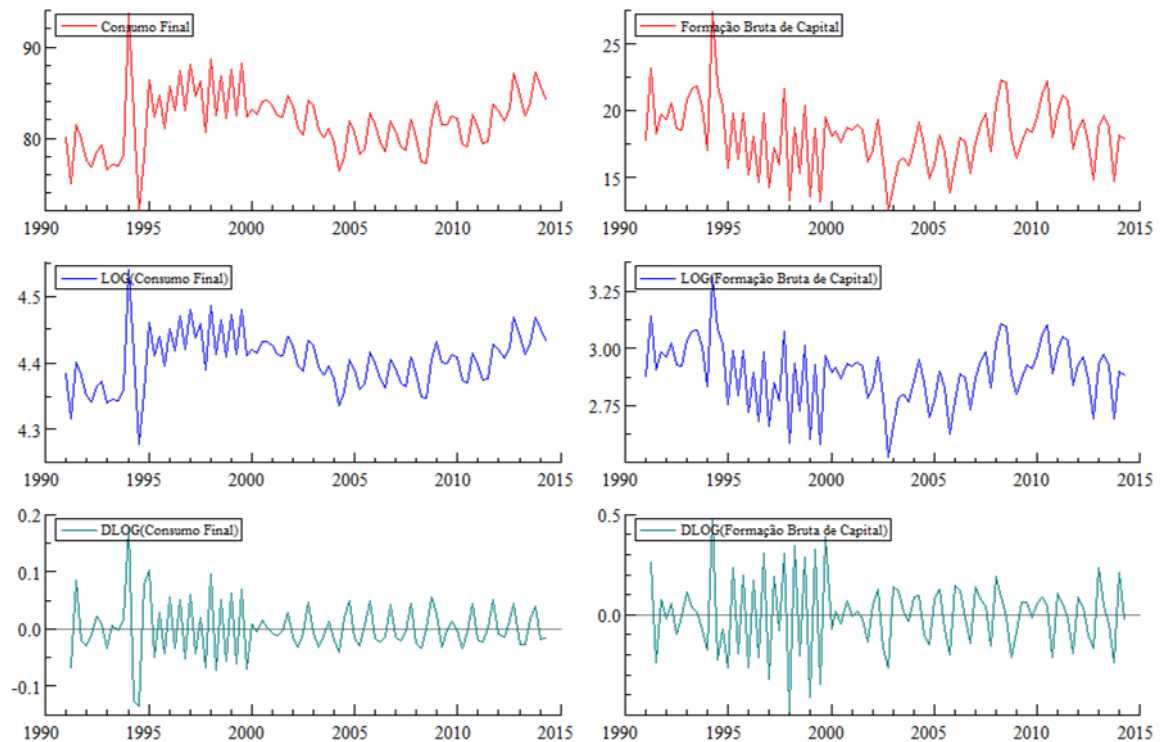
## Ótica da oferta (N2) – Serviços: Comércio, Transporte, Informação e Intermediação Financeira




## Ótica da oferta (N2) – Serviços: Outros Serviços, Imobiliárias e Administração



### Ótica da demanda (N1): Consumo Final, Formação Bruta de Capital

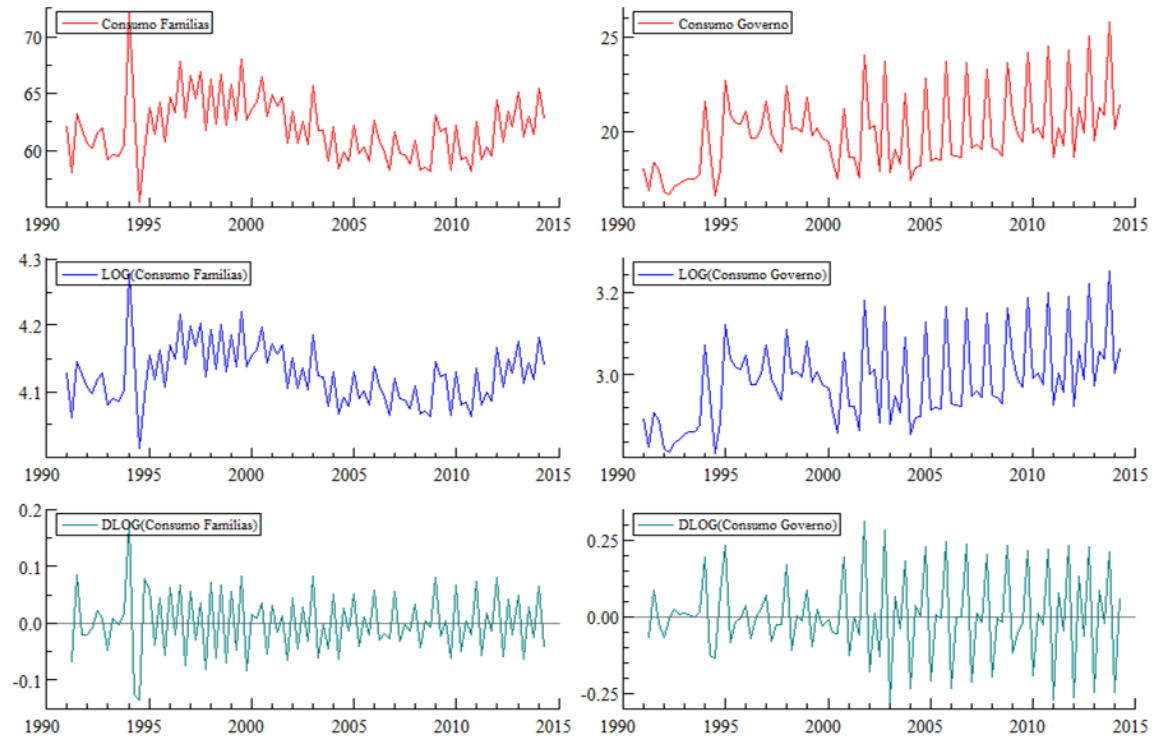


### Ótica da demanda (N1): Exportações e Importações



Observação: Para o indicador de Importações, utiliza-se operação de subtração na ponderação

### Ótica da demanda (N2) – Consumo: Famílias e Governo



## APÊNDICE B - TESTES DE RAIZ UNITÁRIA

### *Resultados dos Testes ADF (Augmented Dickey–Fuller)*

Série	Ótica	Séries Encadeadas		Pesos	
		Estatística t	Prob.	Estatística t	Prob.
PIB	-	-5.676110	0.0000	-	-
Impostos (N1)	Oferta	-5.993230	0.0000	-11.03622	0.0000
Agropecuária (N1)	Oferta	-20.89049	0.0001	-20.53536	0.0000
Indústria (N1)	Oferta	-5.895881	0.0000	-3.552102	0.0088
Extrativa mineral (N2)	Oferta	-5.225577	0.0000	-5.444012	0.0000
Transformação (N2)	Oferta	-5.596764	0.0000	-12.53798	0.0000
Construção (N2)	Oferta	-6.117778	0.0000	-11.99189	0.0000
Eletricidade, gás e água (N2)	Oferta	-5.658849	0.0000	-7.825799	0.0000
Serviços (N1)	Oferta	-4.821292	0.0001	-5.834940	0.0000
Comércio (N2)	Oferta	-5.287697	0.0000	-9.329846	0.0000
Transporte (N2)	Oferta	-5.569820	0.0000	-7.403499	0.0000
Informação (N2)	Oferta	-3.645698	0.0066	-13.07428	0.0000
Intermediação (N2)	Oferta	-2.757443	0.0687	-4.240682	0.0010
Outros serviços (N2)	Oferta	-5.196396	0.0000	-5.968546	0.0000
Imobiliárias (N2)	Oferta	-6.963505	0.0000	-4.007000	0.0022
Administração (N2)	Oferta	-4.659151	0.0002	-6.308384	0.0000
Consumo final (N1)	Demanda	-6.064845	0.0000	-7.471828	0.0000
Famílias (N2)	Demanda	-5.592669	0.0000	-7.641421	0.0000
Governo (N2)	Demanda	-38.29192	0.0000	-6.043784	0.0000
Formação bruta de capital (N1)	Demanda	-4.653370	0.0002	-6.079610	0.0000
Exportações (N1)	Demanda	-5.693935	0.0000	-10.18440	0.0000
Importações (N1)	Demanda	-4.830982	0.0001	-8.800367	0.0000

Fonte: elaborado pelo autor.

Nota: Os testes foram realizados com a primeira diferença do logaritmo das séries, com intercepto e seleção automática pela estatística t em até 5 defasagens, englobando o período de 1991T1 até 2014T2.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Box, G. E. P.; Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control* (2nd ed.). San Francisco, CA: Holden-Day.
- Brüggemann, R., & Lütkepohl, H. (2013). Forecasting contemporaneous aggregates with stochastic aggregation weights. *International Journal of Forecasting*, 29(1), pp. 60-68.
- Carlos, T. C. (2012). *Projeção de inflação no Brasil utilizando dados agregados e desagregados: um teste de poder preditivo por horizonte de tempo*. Dissertação de Mestrado, Escola de Economia de São Paulo da Fundação Getulio Vargas, São Paulo, Brasil.
- Carson, R. T., & Cenesizoglu, T. (2011). Forecasting (aggregate) demand for US commercial air travel. *International Journal of Forecasting*, 27(3), pp. 923-941.
- Chauvet, M. (2002). The Brazilian business cycle and growth cycles. *Revista Brasileira de Economia*, 56, pp. 75-106.
- Commandeur, J., & Koopman, S. (2007). *An Introduction to State Space Time Series Analysis*. Oxford: Oxford University Press.
- Corradi, V., Swanson, N. R., & Olivetti, C. (2001). Predictive ability with cointegrated variables. *Journal of Econometrics*, 104(2), pp. 315-358.
- Diebold, F. X., & Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13(3), pp. 253–263.
- Doornik, J. A. (2009). Autometrics. Em J. Castle, & N. Shephard, *The Methodology and Practice of Econometrics: A Festschrift in Honour of David F. Hendry* (pp. 88-121). New York: Oxford University Press.
- Doornik, J. A., & Hendry, D. F. (2013). *Empirical Econometric Modelling Using PcGive 14: Volume I*. London: Timberlake Consultants Press.
- Durbin, S. J., & Koopman, S. J. (2001). *Time Series Analysis by State Space Methods*. Oxford: Oxford University Press.



- Enders, W. (1995). *Applied Econometric Time Series*. New York: Wiley.
- Espasa, A., Senra, E., & Albacete, R. (2002). Forecasting inflation in the European Monetary Union: A disaggregated approach by countries and by sectors. *The European Journal of Finance*, 8(4), pp. 402-421.
- Ferreira, R. T., Bierens, H., & Castelar, I. (2005). Forecasting quarterly Brazilian GDP growth rate with linear and nonlinear diffusion index models. *Economia Selecta*, 6(3), pp. 261-292.
- Fonseca, M. G. S. (2006). *O repasse cambial no Brasil: uma análise para dados desagregados no período de flutuação do real*. Dissertação de Mestrado, Escola de Pós-Graduação em Economia da Fundação Getulio Vargas, Rio de Janeiro, Brasil.
- Granger C. W. J., & Newbold, P. (1977). *Forecasting economic time series*. Orlando, FL: Academic Press.
- Grunfeld, Y., & Griliches, Z. (1960). Is aggregation necessarily bad? *The Review of Economics and Statistics*, 42(1), pp. 1-13.
- Hamilton, J. D. (1989). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, 57(2), pp. 357-384.
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton: Princeton University Press.
- Hansen, P. R., Lunde, A., & Nason, J. M. (2011). The model confidence set. *Econometrica*, 79(2), pp. 453-497.
- Harvey, A. C. (1989). *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge: Cambridge University Press.
- Harvey, A. C., & Shephard, N. (1993). Structural time series models. Em *Handbook of Statistics* (Vol. 11, pp. 261-302).
- Harvey, D. I.; Leybourne, S. J.; Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting*, 13(2), pp. 281-291.

- Hendry, D. F., & Hubrich, K. (2011). Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate. *Journal of Business & Economic Statistics*, 29(2), pp. 216-227.
- Hendry, D. F., & Krolzig, H.-M. (1999). Improving on 'Data mining reconsidered' by K.D. Hoover and S.J. Perez. *The Econometrics Journal*, 2(2), pp. 202-219.
- Hendry, D. F., & Krolzig, H.-M. (2003). New developments in automatic general-to-specific modelling. Em B. P. Stigum, *Econometrics and the philosophy of economics: Theory-data confrontations in economics* (pp. 379-419). Princeton: Princeton University Press.
- Hendry, D. F., & Krolzig, H.-M. (2005). The properties of automatic Gets modelling. *The Economic Journal*, 115(502), pp. C32-C61.
- Hoover, K., & Perez, S. J. (1999). Data mining reconsidered: encompassing and the general-to-specific approach to specification search. *The Econometrics Journal*, 2(2), pp. 167-191.
- Hubrich, K. (2005). Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting*, 21(1), pp. 119-136.
- Johansen, S. (1988). Statistical analysis of cointegration vectors. *Journal of Economic Dynamics and Control*, 12(2-3), pp. 231-254.
- Kohn, R. (1982). When is an aggregate of a time series efficiently forecast by its past? *Journal of Econometrics*, 18(3), pp. 337-349.
- Lütkepohl, H. (1984). Forecasting contemporaneously aggregated vector ARMA processes. *Journal of Business & Economic Statistics*, 2(3), pp. 201-214.
- Lütkepohl, H. (2010). Forecasting aggregated time series variables - a survey. *Journal of Business Cycle Measurement and Analysis*, 2010/2, pp. 37-62.
- Lütkepohl, H. (2011). Forecasting nonlinear aggregates and aggregates with time-varying weights. *Jahrbücher für Nationalökonomie & Statistik*, 231(1), pp. 107-133.

- Marcellino, M., Stock, J. H., & Watson, M. W. (2003). Macroeconomic forecasting in the Euro area: Country specific versus area-wide information. *European Economic Review*, 47(1), pp. 1-18.
- Martinez, T. S., & Cerqueira, V. S. (2013). Estrutura da inflação brasileira: determinantes e desagregação do IPCA. *Economia e Sociedade*, 22(2), pp. 409-456.
- Meese, R., & Kenneth, R. (1988). Was it real? The exchange rate-interest differential relation over the modern floating-rate period. *The Journal of Finance*, 43(4), pp. 933-948.
- Morgan, W. A. (1939). A test for the significance of the difference between the two variances in a sample from a normal bivariate population. *Biometrika*, 31(1/2), pp. 13-19.
- Nijman, T. E., & Palm, F. C. (1990). Predictive accuracy gain from disaggregate sampling in ARIMA models. *Journal of Business & Economic Statistics*, 8(4), pp. 405-415.
- Pesaran, M. H., Pierse, R. G., & Kumar, M. S. (1989). Econometric analysis of aggregation in the context of linear prediction models. *Econometric*, 57(4), pp. 861-888.
- Rose, D. E. (1977). Forecasting aggregates of independent ARIMA processes. *Journal of Econometrics*, 5(3), pp. 323-345.
- Santos, C., Hendry, D. F., & Johansen, S. (2008). Automatic selection of indicators in a fully saturated regression. *Computational Statistics*, 23(2), pp. 317-335.
- Schumacher, C., & Breitung, J. (2008). Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data. *International Journal of Forecasting*, 24(3), pp. 386–398.
- Schwartzman, F. F. (2006). Estimativa de curva de Phillips para o Brasil com preços desagregados. *Economia Aplicada*, 10(1), pp. 137-155.
- Sims, C. A. (1980). Macroeconomics and reality. *Econometrica*, 48(1), pp. 1-48.

- Stock, J. H., & Watson, M. W. (2002). Macroeconomic forecasting using diffusion indexes. *Journal of Business & Economic Statistics*, 20(2), pp. 147-162.
- Tiao, G. C., & Guttman, I. (1980). Forecasting contemporaneous aggregates of multiple time series. *Journal of Econometrics*, 12(2), pp. 219-230.
- West, K. D. (1996). Asymptotic inference about predictive ability. *Econometrica*, 64(5), pp. 1067-1084.
- White, H. (2000). A reality check for data snooping. *Econometrica*, 68(5), pp. 1097-1126.