Universidade do Estado do Rio de Janeiro
Programa de Pós-Graduação em Ciências Econômicas
Faculdade de Ciências Econômicas

Roberto Nogueira Marques

Previsão da Inflação utilizando modelos de Vetores Autorregressivos e Combinação de previsões pela Otimização MINIMAX: Evidências no Brasil

Rio de Janeiro
2019

Roberto Nogueira Marques

Previsão da Inflação utilizando modelos de Vetores Autorregressivos e Combinação de previsões pela Otimização MINIMAX: Evidências no Brasil

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-graduação em Ciências Econômicas, da Universidade do Estado do Rio de Janeiro. Área de concentração: Economia Aplicada a Métodos Quantitativos.

Orientador: Prof.º Dr. Andrea Ugolini

Coorientador: Prof.º Dr. Carlos Alberto Gonçalves da Silva

Rio de Janeiro

2019

CATALOGAÇÃO NA FONTE

UERJ/REDE SIRIUS/BIBLIOTECA CCS/B

M357 Marques, Roberto Nogueira.
Previsão da inflação utilizando modelos de Vetores Autoregressivos e combinação de previsões pela otimização MINIMAX: evidências no Brasil/Roberto Nogueira Marques. – 2019.
139f.

Orientador: Prof. Dr. Andrea Ugolini.
Coorientador: Prof. Dr. Carlos Alberto Gonçalves da Silva.
Dissertação (mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Ciências Econômicas.
Bibliografia: f.99-105.

1. Economia – Teses. 2. Econometria – Teses. 3. Previsão econômica – Modelos econométricos – Teses. 4. Inflação – Teses. I. Ugolini, Andrea. II. Silva, Carlos Alberto Gonçalves da. III. Universidade do Estado do Rio de Janeiro. Faculdade de Ciências Econômicas. IV. Título.

CDU 330,115

Bibliotecária: Luciana Zöhrer CRB7/5643

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

_____ _____

Assinatura Data

Roberto Nogueira Marques

Previsão da Inflação utilizando modelos de Vetores Autorregressivos e Combinação de previsões pela Otimização MINIMAX: Evidências no Brasil

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-graduação em Ciências Econômicas, da Universidade do Estado do Rio de Janeiro. Área de concentração: Economia Aplicada a Métodos Quantitativos.

Aprovada em 14 de março de 2019.

Banca Examinadora:

_____

Prof. Dr. Andrea Ugolini (Orientador)
PPGCE – UERJ

_____

Prof. Dr. Carlos Alberto Gonçalves da Silva (Coorientador)
PPGCE – UERJ

_____

Prof.ª Dra. Susan Schommer
IE - UFRJ

Rio de Janeiro
2019

DEDICATÓRIA

Dedico este trabalho aos meus pais.

AGRADECIMENTOS

A Deus, pelo dom da vida.

À Marinha do Brasil, pelas condições oferecidas no decorrer deste Curso.

Ao Diretor de Finanças da Marinha, Almirante Hugo, pelo apoio irrestrito.

Aos meus superiores e subordinados do Arsenal de Marinha do Rio de Janeiro, pela confiança, incentivo e amizade.

Aos Oficiais da Diretoria de Finanças da Marinha, em especial, ao Comandante Eduardo, pelo exemplo profissional.

Aos Oficiais da Turma CAIO-2013, pelo incentivo, motivação e amizade.

Aos professores e funcionários do PPGCE, pela disposição, dedicação e resiliência.

Aos Professores Dr. Andrea e Dr. Carlos Alberto, pelas sinceras orientações, paciência com minhas limitações e correição detalhada deste trabalho.

À Professora Dra. Susan, pelo apoio, *insights* e orientações que contribuíram para realização deste trabalho.

Aos amigos do PPGCE, pelo agradável convívio. A amizade de vocês é um dos legados deste Curso em minha vida.

À minha namorada Stephania, por ser porto seguro com águas tranquilas e abrigadas.

À minha irmã Mariana, por ter enchido nossos corações de alegria com o nascimento do Pedro, além do carinho, incentivo e amizade.

Aos meus pais, Graça e Roberto, pelo amor à família e renúncia em favor da minha educação desde a minha infância.

RESUMO

MARQUES, R.N. **Previsão da Inflação utilizando modelos de Vetores Autorregressivos e Combinação de previsões pela Otimização MINIMAX:** Evidências no Brasil.2019. 140f. Dissertação (Mestrado em Economia Aplicada) - Programa de Pós Graduação em Ciências Econômicas, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

Esta dissertação tem como propósito apresentar contribuições que viabilizem melhorias na capacidade de previsão dos modelos de Vetores Autorregressivos (VAR) por ser um método de resultados avaliados como acurados no curto e no médio prazo e de baixa complexidade (Lima; Araújo; Silva, 2009).Mais especificamente, realizamos a previsão do índice de preços ao consumidor amplo (IPCA)através da estimação de modelos VAR utilizando-se de combinações lineares de programação matemática (PPM) multiobjetivo MINIMAX que permitissem aos modelos VAR atingirem maior acurácia. Os resultados deste trabalho nos apontam que, em média, pelo método estático, as previsões combinadas de inflação calculadas pela combinação de previsões que minimizam o erro quadrático médio (MSE) e as 3 estatísticas (MAPE, MAE e MSE) superam um modelo *Naïve* usado como referência (*benchmark*) e o modelo VAR de previsão individual com maior acurácia. Isso é observado principalmente para previsões com 6 e 12 passos à frente. Pelo método dinâmico, no horizonte de 12 meses as previsões foram mais acuradas que àqueles do modelo referência.

Palavras-chave: Inflação. Modelos Econométricos. Previsão. Combinação de Previsões. Otimização Multiobjetivo. Programação por Metas. MINIMAX.

ABSTRACT

MARQUES, R.N. **Inflation Forecasting by Vector Autoregression models and Combination of forecast using Optimization MINIMAX**: Evidence from Brazil.2019. 140 f. Dissertação (Mestrado em Economia Aplicada) - Programa de Pós Graduação em Ciências Econômicas, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019.

The purpose of this dissertation is to present contributions that enable improvements in the predictive capacity of Autoregressive Vectors models(VAR) as a method of results evaluated as accurate in the short and medium term and of low complexity (Lima, Araújo, Silva, 2009) . More specifically, we performed the prediction of the consumer price index (IPCA) by estimating VAR models using linear multi-objective MINIMAX mathematical programming combinations (PPM) that allowed the VAR models to reach higher accuracy. The results of this work indicate that, on average, by the static method, the combined inflation forecasts calculated by the combination of predictions that minimize the mean square error (MSE) and the three statistics (MAPE, MAE and MSE) surpass a used Naïve model as benchmark and the most accurate individual forecast VAR model. This is mainly observed for forecasts with 6 and 12 steps forward. By the dynamic method, in the 12-month horizon the forecasts were more accurate than those of the reference model.

Keywords: Inflation. Econometric Models. Forecast. Forecast Combination. Multiple Objective Optimization. Goal Programming. MINIMAX.

LISTA DE ILUSTRAÇÕES

Quadro 1 - Resumo das literaturas internacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo.... 31

Quadro 2 - Resumo das literaturas nacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo..... 34

Quadro 3 - Modelagens VAR utilizadas para estimação e previsão da inflação..... 40

Quadro 4 - Descrição das variáveis dependente e explicativas utilizadas nos modelos..... 52

Quadro 5 - Resumo dos VAR utilizados para estimação e previsão..... 66

Quadro 6- Extrato da estimação dos 4 modelos VAR com 1 defasagem no período amostral: 2002M03 até 2016M12..... 68

Quadro 7- Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 12 passos à frente..... 113

Quadro 8- Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 6 passos à frente..... 121

Quadro 9- Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 3 passos à frente..... 130

Quadro 10- Resumo de modelagens pelos menores Erros Quadráticos Médios..... 94

LISTA DE GRÁFICOS

Gráfico 1-	Séries temporais das variáveis explicativas e explicadas em nível.....	54
Gráfico 2 -	Séries temporais das variáveis explicativas e explicadas em primeiras diferenças.....	105
Gráfico 3 -	Raízes inversas do polinômio característico.....	61
Gráfico 4 -	Funções de resposta ao impulso (FRI) dos modelos VAR com 1 defasagem.....	69
Gráfico 5-	Funções de resposta ao impulso (FRI) dos modelos VAR com 2 defasagem.....	111
Gráfico 6-	Funções de resposta ao impulso (FRI) dos modelos VAR com 3 defasagem.....	112
Gráfico 7-	Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (12 passos à frente).....	73
Gráfico 8-	Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método dinâmico (12 passos à frente).....	75
Gráfico 9-	Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (6 passos à frente).....	77
Gráfico 10-	Retorno IPCA acumulado e valores projetados dos 3 modelos VAR com menor MSE com base no método dinâmico: 6 passos à frente.....	78
Gráfico 11 -	Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (3 passos à frente).....	80

Gráfico 12 - Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método dinâmico (3 passos à frente)..... 81
Gráfico 13 - Retorno IPCA acumulado, previsões individuais do modelo VAR com menor MSE e previsões combinadas com base no método estático (12 passos à frente)..... 85
Gráfico 14 - Retorno IPCA acumulado, previsões individuais dos 2 modelos VAR com menor MSE e previsões combinadas com base no método dinâmico (12 passos à frente)..... 86
Gráfico 15 - Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método estático (6 passos à frente)..... 88
Gráfico 16 - Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método dinâmico (6 passos à frente)..... 89
Gráfico 17 - Retorno IPCA acumulado e previsão com base no método estático: 3 passos à frente..... 90
Gráfico 18 - Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método dinâmico (3 passos à frente)..... 91

LISTA DE TABELAS

Tabela 1 - Estatísticas descritivas das séries temporais em nível e teste Jarque-Bera..... 55

Tabela 2 - Teste de raiz unitária ADF, PP e KPSS em nível..... 58

Tabela 3 - Teste de raiz unitária ADF, PP e KPSS em primeira diferença.. 59

Tabela 4 - Resultados dos testes do traço e máximo autovalor (cointegração)..... 106

Tabela 5 - Resultados dos testes de seleção de ordem de defasagens no período amostral de 2002M01 até 2016M12..... 109

Tabela 6 - Testes de causalidade de Granger..... 64

Tabela 7 - Retorno IPCA acumulado: previsões individuais pelos modelos VAR com base no método estático (12 passos à frente)..... 72

Tabela 8 - Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (12 passos à frente)..... 74

Tabela 9 - Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método estático (6 passos à frente)..... 77

Tabela 10 - Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (6 passos à frente)..... 78

Tabela 11 - Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método estático (3 passos à frente)..... 80

Tabela 12 - Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (3 passos à frente)..... 81

Tabela 13 - Retorno IPCA acumulado, previsões individuais dos modelos VAR com menor MSE e previsões combinadas com base no método estático (12 passos à frente)..... 84

Tabela 14 - Retorno IPCA acumulado, previsões individuais dos modelos VAR com menor MSE e previsões combinadas com base no método dinâmico (12 passos à frente)..... 84
Tabela 15 - Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método estático (6 passos à frente)..... 87
Tabela 16 - Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método dinâmico (6 passos à frente)..... 89
Tabela 17 - Retorno IPCA acumulado, previsões individual dos modelo VAR com menor MSE e previsões combinadas com base no método estático (3 passos à frente)..... 90
Tabela 18 - Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método dinâmico (3 passos à frente)..... 91
Tabela 19 - Avaliação da Acurácia dos modelos 3, 6 e 12 passos à frente... 93

SUMÁRIO

INTRODUÇÃO 13

2 REVISÂO DE LITERATURA 17

2.1 Literatura internacional 17

2.2 Literatura nacional 22

2.3 Programação por Metas 27

3 METODOLOGIA 37

3.1 Modelos de Vetores Autorregressivos 37

3.2 Previsão através de Modelos de Vetores Autorregressivos 43

3.3 Combinação de Previsões, Otimização MINIMAX e Métodos de Comparação preditiva 45

4 DADOS 51

5 RESULTADOS EMPÍRICOS E ANÁLISES 57

5.1 Testes de raiz unitária e gráficos das séries temporais 57

5.2 Resultados das estimações e funções de resposta ao impulso 66

5.3 Previsões individuais 70

5.4 Combinação de Previsões individuais 82

5.5 Avaliação de Previsões 92

6 - CONSIDERAÇÕES FINAIS 96

REFERÊNCIAS 98

ANEXO A – Anexo Estatístico 105

INTRODUÇÃO

A Inflação é uma variável macroeconômica utilizada para a tomada de decisão dos agentes. A importância da inflação e seus desdobramentos no que tange ao comportamento da economia na condução de política macroeconômica é sabido por todos.

Empresas ao decidirem sobre produção, investimento e consumo; famílias ao decidirem sobre quanto consumir e poupar; o governo ao decidir o quanto gastar, investir e arrecadar de tributos; e o Banco Central ao decidir sobre política monetária; se baseiam no nível geral de preços.

Por meio de modelos econométricos, é possível prever a inflação de uma economia. Os resultados obtidos a partir dos modelos de previsão visam fundamentar as decisões futuras dos agentes econômicos para que não apenas tomem decisões com base experiência passada do funcionamento da economia.

> “The lessons of past experience are by no means immediately – if ever clear, nor is it easy to gauge how the economy might be operating differently now from how it has done in the past”. (BoE, 1999, p. 3)

Entende-se que a economia pode operar de maneira diferente no período atual, em comparação, ao passado mesmo que recente. Desta maneira, modelos bem construídos e selecionados são capazes de simplificar e esclarecer os problemas econômicos, concentrando-se nos fatores-chave para a sua compreensão (BoE, 1999).

Ao utilizarmos Modelos, sabemos que estes tratam-se de representações simplificadas da realidade que são capazes de apresentar a estrutura que a atividade econômica se desenvolve. Com base nos modelos econômicos, o pesquisador pode disciplinar e organizar seu pensamento científico; compreender os riscos e pressupostos; comunicá-los com transparência; e produzir previsões e cenários (CUSBERT E KENDALL, 2018).

Como os modelos econômicos são projetados para simplificar o mundo real, eles visam considerar as variáveis e mecanismos potencialmente importantes, ou seja, focalizam a análise nas variáveis que possuem maior utilidade e eficiência para o estudo que será realizado.

Ao desenvolver um modelo econômico, é necessário investigar as relações e mecanismos de causalidade que importam àqueles que farão uso do modelo elaborado. Sob o ponto de vista dos agentes interessados na trajetória de inflação de uma economia, os mecanismos e instrumentos que mais importam são aqueles que através do ciclo econômico afetam a política monetária.

No Brasil, com a adoção do Sistema de Metas de Inflação (SMI) em 1999, tornou-se necessária a criação e melhoria de modelos de previsão no âmbito do Banco Central do Brasil (BCB), para o acompanhamento das projeções do comportamento das variáveis macroeconômicas, em particular, a inflação.

Em face dos efeitos de uma política monetária sobre os preços de uma economia se desdobrarem com defasagens, em conjunto com a tarefa de se manter a inflação alinhada com as metas previamente definidas, tornam necessário o uso de instrumentos capazes de gerar previsões de inflação confiáveis. Dentre os diversos índices de inflação brasileira destacamos o Índice de Preços as Consumidor Amplo (IPCA) cuja mensuração é realizada pelo IBGE, o qual, foi definido como referência para o acompanhamento dos efeitos de políticas monetárias no país.

Sob o espectro do Sistema de Metas de Inflação (SMI), o que se espera de um eficiente modelo é que tenha capacidade de prever se a inflação acumulada dos 12 meses adiante ao período analisado, estará dentro da meta. Em termos econômicos, não é tão esclarecedor que se utilize um modelo que seja capaz de prever apenas qual será a inflação em um mês ou trimestre específico, mas o quanto a inflação acumulada está próxima do centro da meta estabelecida, no caso brasileiro, pelo Conselho Monetário Nacional (CMN). Assim, modelos de previsão de inflação são fonte de informação para o processo decisório do Comitê de Política Monetária (COPOM) e para demais agentes econômicos que necessitam obter uma estimação mais acurada da inflação.

Embora exista uma diversidade de modelos de previsão de inflação, o presente trabalho utiliza os modelos de vetores autorregressivos (VAR) como metodologia de previsão da inflação de preços, uma vez que são capazes de estimar estatisticamente as interações dinâmicas entre um conjunto de variáveis sem a necessidade do estabelecimento de hipóteses teoricamente fortes. Com isso, tornam-se úteis para captura de fatos estilizados sobre correlações dinâmicas entre variáveis econômica de maneira menos restrita (BoE, 1999). Além de serem capazes de fazer previsões

com baixo erro preditivo, especialmente no curto prazo (LIMA; ARAÚJO; SILVA, 2011).

Os modelos VAR, como qualquer outro modelo econômico, são suscetíveis a críticas. No entanto, a capacidade que possuem de gerar previsões satisfatórias se comprova pela sua utilização e constante revisão pelos Bancos Centrais da Inglaterra (BoE, 1999), do Chile (Banco Central de Chile, 2003), da Suíça (SNB, 2006), da Austrália (RBA, 2010) e do Brasil (BCB, 2012 e 2013) para prever inflação. Os modelos VAR estimados pelo Banco Central do Brasil passam por revisões e atualizações regularmente.

Na existência de mais de um modelo de previsão, espera-se que um tenha melhor performance que outro, ou seja, possua desempenho previsor mais acurado que os demais (BATES E GRANGER, 1969). Os autores são pioneiros no estudo de combinação de previsões, cujo princípio é a possibilidade de aumentar a precisão das previsões através da complementaridade obtida em cada previsão individual.

Em termos gerais, existem três motivos que justificam a necessidade de combinar previsões uma vez que podem ser esperadas melhoria de precisão dos resultados. De acordo com Jordan e Savioz (2003), a combinação leva a uma diversificação dos erros de previsão, o que reduz o problema de estimativas imprecisas de modelos individuais. Além disso, as previsões quando combinadas demonstram-se mais robustas, porque não são atreladas as especificações de um modelo individual. Assim, na ocorrência de erro de especificação em um único modelo a combinação poderá suavizar a incorreção. Por fim, as previsões quando combinadas estão baseadas em um conjunto de informações mais amplo, ou seja, são consideradas mais variáveis. Como as previsões por modelos VAR utilizam poucas variáveis torna-se relevante buscar meios de combina-los em face da perda dos graus de liberdade que ocorrem quando são necessários um grande número de parâmetros a ser estimado.

Adicionalmente,

> Uma vez obtidas as previsões de cada uma das especificações, combinam-se elas de modo a reduzir o erro de previsão. A estratégia de combinação de previsões vem se tornando cada vez mais difundida, e o ponto mais controverso dessa estratégia é a escolha dos pesos ótimos de cada previsão no resultado final. (LIMA; ARAÚJO; SILVA, 2011, p. 374)

Jordan e Savioz (2003) afirmam que os ganhos da combinação de previsões, em particular, surgem quando os pesos dependem sobre o desempenho passado das previsões individuais.

Assim sendo, esta dissertação tem como objetivo apresentar contribuições que viabilizem melhorias na capacidade de previsão da inflação com base nos modelos VAR por ser um método de resultados avaliados como acurados no curto e no médio prazo; e de baixa complexidade (LIMA; ARAÚJO; SILVA, 2011). A previsão do índice de preços foi estimada pelos modelos VAR utilizando-se de combinações lineares de programação matemática (PPM) multiobjetivo MINIMAX que fossem capazes de permitir os modelos VAR atingirem maior acurácia. Cabe destacar que a combinação linear por PPM multiobjetivo MINIMAX tem sido utilizada em outras áreas. Segundo Correa, et al. (2016), este método para combinação linear de previsões apresentou um desempenho superior aos métodos individuais, dentro e fora da amostra na previsão de valores futuros da demanda de eletricidade.

Mais especificamente, objetivo principal desta dissertação é analisar empiricamente modelos VAR e com base em técnicas de combinação de métodos preditivos apresentar inovações capazes de gerar melhorias nas previsões da inflação brasileira. Em relação aos objetivos específicos pretende-se estimar quatro modelos de Vetores Autorregressivos (VAR) distintos com até 3 defasagens. Em seguida, calcular previsões dos quatro modelos VAR estimados individualmente, considerando apenas os erros quadráticos médios (MSE) e, por fim, realizar a combinação linear dos quatro modelos VAR estimados com pesos determinados por meio de um modelo de programação matemática multiobjetivo MINIMAX, tendo como funções objetivo a minimização do desvio médio máximo referentes as estatísticas: erro quadrático médio (MSE), erro médio absoluto (MAE) e erro médio percentual absoluto (MAPE). Por meio deste trabalho, pretende-se formalizar um método de projeção de inflação pelos modelos de vetores autorregressivos (VAR) e apresentar inovações a fim de permitir previsões mais acuradas a partir de combinações de previsões.

A dissertação está dividida em 5 capítulos, além desta introdução. O capítulo 2 apresenta revisão de literatura, a qual fundamenta teórica e empiricamente a pesquisa proposta. No capítulo 3 apresenta-se a metodologia e os dados que foram utilizados no trabalho empírico. O capítulo 4 apresenta e analisa os resultados empíricos encontrados na pesquisa. O capítulo 5 realiza uma síntese final da dissertação.

2 REVISÂO DE LITERATURA

O objetivo deste capítulo é apresentar um *survey* da literatura internacional e nacional que analisaram os modelos de previsões, sobretudo quanto à de previsões de inflação, a partir de metodologias de modelos econométricos. Ademais, neste capítulo são apresentadas breves revisões sobre programação por metas.

Na seção literatura internacional, apresentamos trabalhos com modelos relevantes para previsão da inflação dos Estados Unidos desde o período dos choques nos preços do barril petróleo no mercado mundial nos anos 70. Na seção literatura nacional, apresentamos trabalhos que abordaram o caso brasileiro. Desta forma, foi possível observar que houve uma predominância de análises preditivas após a adoção do Plano Real e do regime de metas. Ou seja, uma das consequências regime de metas, foi a elaboração de diversos trabalhos capazes de gerar projeções sobre a inflação média da economia e auxiliar nas decisões de política monetária por parte do Banco Central do Brasil. Por fim, na seção programação por metas, foram apresentados os principais conceitos que envolvem o tema, além de como auxiliam na solução de problemas que possuem objetivos conflitantes ou não com as metas.

2.1 Literatura internacional

A fim de balizar a decisão dos agentes econômicos no que diz respeito a investimento, poupança, alocação de ativos e de política econômica, na literatura internacional encontramos diversos trabalhos que visam prever a trajetória da inflação e demais variáveis macroeconômicas de maneira que os modelos possam gerar informação efetiva e segura.

Meltzer (2005) sumarizou estudos desenvolvidos nos anos 80 que buscaram avaliar a capacidade de previsão da inflação dos Estados Unidos ao longo dos anos 1960-70 através da curva de Phillips(1958) sem considerar que os agentes tomam decisões com base em expectativas adaptativas. Os resultados comprovaram que as previsões e *policymakers* subestimaram, a inflação. O período que compreende o fim do regime de Bretton Woods (1973), os choques nos preços do petróleo no mercado

mundial (1973-1974 e 1978-1979) e a política monetária expansionista utilizada como instrumento de redução da taxa de desemprego foram denominados como *Great Inflation*. Neste período, a elevação do patamar da inflação nos Estados Unidos gerou um processo de “miopia” dos agentes, isto porque qualquer tentativa de previsão do comportamento da economia não era trivial, ou seja, parecido com o observado nos períodos anteriores.

Em face disso, a curva de Phillips(1958), por ser uma das principais equações dos modelos macroeconômicos da época, despertou o interesse da investigação de novas modelagens que pudessem gerar melhores previsões para a inflação. A curva de Phillips na versão Friedman(1968) e Phelps (1967 e 1968), i.e., do tipo “aceleracionista” ou com expectativas aumentadas, trouxe inovações para a modelagem de Phillips(1958) o que devido as previsões satisfatórias nas décadas de 70 e 80 concedeu uma sobrevida nestes modelos de previsão.

Stockton e Glassman (1987) fizeram análises e comparações no período de 1977 a 1984 dos modelos: monetarista tradicional, modelo de expectativas racionais, curva de Phillips com expectativas aumentadas(Gordon,1982) e modelo autorregressivo ARIMA(4,1,0). Segundo os autores, a curva de Phillips com expectativas aumentadas teve melhores resultados do que os demais modelos estruturais. Estes resultados foram confirmados por Mehra (1988) visto que as melhores previsões pela curva de Phillips na versão de Gordon (1982) foram obtidas para o último trimestre de 1980 ao último de 1985, uma vez que foi capaz de prever a acentuada desaceleração da taxa de inflação ocorrida no início dos anos 80.

Jaditz e Sayers (1994 apud STOCK E WATSON, 2008) observaram redução da capacidade de previsões da curva de Phillips com expectativas aumentadas. Para chegarem a esta conclusão, previram através de um modelo VAR e um VECM a inflação plena dos Estados Unidos (CPI) um mês adiante para o período de 1986 a 1991 utilizando como variáveis: dados da produção industrial, do índice de preços ao produtor (*Producer Price Index*) e dos títulos do tesouro. Suas conclusões demostraram que as previsões do modelo univariado autorregressivo AR (1) utilizado como modelo referência são mais acuradas do que as previsões da curva de Phillips.

Cecchetti (1995) fez previsões do CPI (inflação plena dos Estados Unidos) para os horizontes de 1 a 4 anos durante os anos de 1977-1994 e 1987-1994. As previsões a partir da curva de Phillips tiveram bom desempenho em ambos períodos. No entanto, observou existência de quebras nas relações das variáveis inflação *versus*

desemprego, inflação *versus* razão emprego/população e inflação *versus* taxa de utilização da capacidade instalada demonstrando evidências de instabilidade nas previsões pela curva de Phillips. Além disso, também descobriu que um bom ajuste *in-sample* é não relacionado ao desempenho futuro de previsão.

Stock e Watson (1999), nos períodos de 1970-1983 e 1984-1996, fizeram previsões para a inflação do consumidor urbano dos Estados Unidos e dos gastos com consumo pessoal a partir do CPI-U (*Consumer Price Index for All Urban Consumers*) e pelo PCE-all (Personal Consumption Expenditure), no horizonte de 12 meses utilizando 168 indicadores econômicos (85 dos indicadores estão associados a atividade da economia real). No entanto, observaram que os resultados empíricos indicam que as previsões da curva de Phillips usando variáveis de atividade da economia real são melhores do que outras previsões multivariadas, mas seu desempenho é episódico, porque os resultados oscilam entre melhores e às vezes piores do que um bom modelo univariado (não Naïve).

Cecchetti, Chu e Steindel (2000) ao preverem a inflação plena dos Estados Unidos (CPI) a partir de variáveis de atividade (desemprego, a razão entre emprego e população e a taxa de utilização da capacidade) demonstraram que, comparativamente a estas, as previsões dos modelo AR *(benchmark*) são mais acuradas. Porém, o período de amostragem e da especificação do modelo influenciam na acurácia das previsões. Da mesma maneira, Atkeson e Ohanian (2001) e Fisher, Liu e Zhou (2002) concluíram que ao serem geradas previsões a partir da curva de Phillips a definição do período da amostra irá influenciar os resultados (resultados instáveis) além de apresentarem um desempenho relativamente fraco em períodos de baixa volatilidade da inflação e após uma mudança de regime.

Atkeson e Ohanian (2001) compararam a precisão de projeções de inflação entre 1984 a 1999 a partir de um modelo *Naïve*, usado como referência, com modelos curva de Phillips NAIRU (*Non-Accelerating Inflation Rate of Unemployment*). O modelo *Naïve* considerou a inflação futura como igual à inflação do período passado. As previsões foram calculadas para o período de um ano adiante. Contudo, os modelos estruturais (curva de Phillips) tiveram acurácia inferior ao modelo ateórico simples (*Naïve*) usado como referência. Com isso, os autores concluíram que a modelagem baseada na curva de Phillips, não provou ser útil para a previsão da inflação nos período entre 1984 e 1999.

Os resultados dos trabalhos de Banerjee e Marcellino (2002), Ang, Bekaert e Wei (2005) e Clark e McCracken (2005) podem ser usados como contraponto às conclusões de Atkeson e Ohanian (2001).

Stock e Watson (2003) ampliaram a análise de Atkeson e Ohanian (2001) pela inclusão de mais preditores da atividade da economia real e corroboraram o melhor desempenho observado das previsões oriundas do modelo *Naïve* para o período de 1985-1999, com horizonte de um ano. Brave and Fisher (2004) também analisaram com preditores adicionais a modelagem de Atkeson e Ohanian (2001). Os autores encontraram resultados consistentes com Fisher, Liu e Zhou (2002) no sentido que algumas previsões individuais e combinadas superam Atkeson e Ohanian (2001) ao longo de 1993-2000, embora não mais de 1985-1992.

Orphanides e van Norden (2005) calcularam as previsões da curva de Phillips através do hiato do produto em tempo real e concluíram que embora as curvas de Phillips *ex-post* se ajustem aos dados dentro-da-amostra (*in-sample*), o mesmo não ocorre quando utilizam hiato do produto em tempo real e pseudo-fora de amostra. Uma vez que estas mudanças da modelagem melhoram o modelo autorregressivo (AR *benchmark*) antes de 1983, mas não o fazem na amostra 1984-2002.

Stock e Watson (2007) comparam as previsões de inflação realizada por três modelos: um modelo AR como *benchmark*, o modelo de Atkeson e Ohanian (2001) e uma curva de Phillips *backward-looking* especificada com a taxa de desemprego em nível com NAIRU constante. Os autores analisam 2 períodos amostrais: primeiro trimestre de 1970 ao quarto trimestre de 1983; e primeiro trimestre de 1984 ao quarto trimestre de 2004. As variáveis analisadas são índice de preços do PIB como variável representativa da inflação. As variáveis de atividade utilizadas são a taxa de desemprego, o logaritmo do PIB real, a taxa de utilização da capacidade, licenças de construção e um índice de atividade. Os autores concluem que a partir da RMSE[1] o erro de previsões diminuiu após o início de 1984.

Em complemento, os autores observaram que do primeiro trimestre de 1970 ao quarto trimestre de 1983 para o primeiro trimestre de 1984 ao quarto trimestre de 2004 as previsões obtidas através da curva de Phillips se tornaram menos precisas, mesmo utilizando modelagem cuja especificação possibilite a que a NAIRU ou o produto potencial variar no tempo. As previsões provenientes do modelo de Atkeson e

[1]*Root Mean Square Error*, tradução nossa, Raiz Quadrada do Erro quadrático Médio

Ohanian (2001) apresentaram melhor desempenho sobre o modelo *benchmark* e sobre a curva de Phillips de horizontes preditivos mais longos, i.e., com quatro e oito trimestres no período pós 1984. Os autores também observaram mudanças na variância do componente permanente (captura a tendência de inflação), ao passo que a variância do componente transitório (captura os desvios de seu valor de tendência), desde meados dos anos 1950, permaneceu constante. Segundo Stock e Watson (2007) essas alterações se originam de mudanças pós 1984 na condução da política monetária, na estrutura da economia real, no desenvolvimento dos mercados financeiros e de possíveis mudanças da estrutura dos choques econômicos.

Cecchetti et al. (2007) pela análise das mudanças na dinâmica inflacionária que os países do G7 entre os anos 1960 a 2006 corrobora as conclusões de Stock e Watson (2007). Para os autores, são semelhantes as mudanças ocorridas nos Estados Unidos, a desaceleração da inflação deve-se à adoção de regimes de política monetária desde a década de 1980. Para Cecchetti et al.(2007), a origem da *Great Inflation* (1973-1974 e 1978-1979) é explicada tanto pela implementação de políticas monetárias acomodatícias (aquelas que não são capazes de reagir aos efeitos decorrentes da variação fiscal) quanto pela ocorrência de choques nos preços do petróleo.

Hall e Jääskelä (2011) a partir de 2 amostras de países selecionados, entre os que adotaram metas de inflação e os que não adotaram, constataram que não é trivial distinguir o regime monetário que permitia a inflação comportar-se como menos volátil. No entanto, a previsão em ambos os grupos de países tornou-se mais fácil depois da adoção do regime de metas desde o início dos anos 90, mas os erros de previsão permaneceram um pouco menores no grupo de países que não adotaram o regime. A análise é baseada numa versão modificada do modelo de Stock e Watson (2007). As previsões do modelo modificado são geralmente superiores aos *benchmarks* simples e ao modelo original Stock e Watson.

De acordo com Hall e Jääskelä (2011), a previsibilidade da inflação está associada a uma política monetária eficaz e crível, *ceteris paribus*, capaz de manter a inflação ancorada em torno de uma média baixa e constante. Por si só, isso implica que a inflação deve ser mais fácil de prever; i.e., as previsões seriam mais acuradas. Com base nisso, podemos dizer que a substituição do regime de política monetária dos Estados Unidos baseado em medidas discricionárias pela utilização de políticas de controle de alguma variável nominal (taxa de câmbio nominal, agregado monetário

ou taxa de inflação) e de transparência dos atos do banco central foram capazes de influenciar o nível e a volatilidade da inflação tornando a inflação americana mais previsível.

Para Chan (2013), a baixa previsibilidade de modelos multivariados e estruturais, como a curva de Phillips, consiste no fato que as variáveis relevantes utilizadas para prever a inflação se modificam no decorrer do tempo. Logo, estas alterações dificultam a compreensão do funcionamento da dinâmica inflacionária, de modo que as expectativas dos agentes são mais imprecisas. Segundo a autora, o preço do petróleo pode conter informações que auxiliam na previsão da inflação na década de 1970 mas isso pode não se repetir em outra década ou fase dos ciclos de negócios, i.e., algumas variáveis podem ajudar a prever bem em períodos de expansões mas não de recessões.

No entanto, a modelagem baseada na Curva de Phillips e suas variações, principalmente nos períodos pós-1984, não foram capazes de superar as previsões obtidas com base nos modelos autorregressivos simples e modelos Naïve. Ou seja, os modelos com fundamentação econômica não foram capazes de superar com resultados robustos as previsões dos modelos estatísticos apesar da melhoria nas técnicas preditivas. Com isso, podemos afirmar que prever a inflação é uma tarefa complexa e não-trivial, mas essencial para o sucesso da implementação de política monetária.

2.2 Literatura nacional

Entre meados dos anos 1980 e 1994 a taxa de inflação brasileira foi elevada. Os diversos planos econômicos criados pelo governo com o objetivo de controlar ou arrefecer o nível geral de preços foram malsucedidos uma vez que apenas temporariamente conseguiam aliviar as pressões inflacionárias. A literatura nacional que trata do processo inflacionário brasileiro é tão extensa quanto a americana.

Fraga (2011) na ocasião dos 10 anos de implantação do regime de metas de inflação fez breve relato sobre a situação brasileira que levaram ao Plano Real e a escolha do regime de metas. Segundo ele, a inflação sem controle alcançou valores elevados nos anos 80 e no início dos 90, havendo inclusive períodos onde ocorreu

hiperinflação. As tentativas de conter a escalada dos preços através de planos heterodoxos de estabilização anteriores ao plano Real fracassaram. Apesar da experiência passada, o Plano Real foi capaz de sucumbir a inflação através da combinação de austeridade monetária (adoção de âncora cambial) e desindexação (através da URV[2]). Contudo, a partir de 1998, devido a uma conjuntura global de crise nos países em desenvolvimento e por uma política fiscal frágil levaram ao enfraquecimento da âncora cambial (“dólar-real um para um”).

No início de 1999, o regime cambial brasileiro deixou de ser fixo para ser flutuante. Logo, as expectativas de inflação se desancoraram do dólar americano. A fim de não perder a estabilidade de preços alcançada até então, foi necessária a implantação de nova sistemática. As alternativas naquele momento eram: o estabelecimento de regime de metas de inflação; estabelecimento de câmbio fixo ou administrado; a criação de uma caixa de conversão como a da Argentina (um rígido *currency board*); a introdução de metas para agregados monetários (notoriamente instáveis); ou a política monetária sem meta explícita para a inflação. A opção pelo sistema de metas para a inflação, a exemplo de países como o Reino Unido, a Suécia e a Nova Zelândia, surgiu como o sistema mais eficaz.

Com base nisso, entendemos que é incontestável a mudança no comportamento da inflação após a adoção do Plano Real e do regime de metas. A partir da implantação do Plano Real a inflação mensal foi reduzida assim como houve redução da volatilidade. Outra mudança de comportamento dos preços foi a redução dos picos na série a partir da mudança na condução da política monetária com a adoção do regime de metas.

Para De Mendonça e Inhundes (2010) o regime de metas inflacionárias e consequente maior transparência na condução da política monetária influenciaram no comportamento menos volátil da inflação e das variáveis reais devido a uma maior capacidade de previsão do índice de preços possibilitando maiores horizontes de planejamento por parte dos agentes econômicos em relação à tomada de decisões.

Dentre os trabalhos voltados para as previsões da inflação no Brasil existe uma variada gama de estudos que analisam diversos períodos após o Plano Real,

[2]Segundo Portugal (2016), durante a implantação do Plano Real, a URV (Unidade Real de Valor) foi pré-anunciada pelo governo como a nova moeda. Esta Unidade era um índice contemporâneo que acompanhava a taxa de câmbio e propiciava a conversão de contratos, preços e salários. Isto facilitou o alinhamento relativo de preços para um regime de inflação baixa. Com isso, a URV guiava as expectativas dos agentes.

compreendendo desde modelos simples até outros de modelagem complexa mas com erros preditivos maiores.

BCB (2003) considerando o período amostral entre o terceiro trimestre de 1999 e o quarto trimestre de 2002, comparou projeções de inflação do BCB com as projeções feitas pelo mercado (FOCUS[3]). Os resultados obtidos foram que ambas as previsões apresentaram viés negativo desde o primeiro trimestre de 2001. Ou seja, as previsões de ambos os agentes tem subestimado o IPCA. Isto nos sugere que a economia brasileira tem estado sujeita a choques não antecipados tanto pela estimativa do mercado quanto pelas projeções do BCB. Quanto ao grau de dispersão das previsões, há evidências de que o Banco Central e o mercado não possuem medidas de dispersão estatisticamente iguais.

Lima e Céspedes (2006) avaliaram o desempenho das previsões do mercado (contidas no relatório FOCUS) e do Banco Central do Brasil (BCB) em diferentes horizontes de previsão no período amostral compreendido entre janeiro de 2000 a abril de 2005 através de modelos univariados lineares (AR e ARMA). Segundo os autores, não existe qualquer evidência que o relatório Focus e relatório de inflação do BCB prevejam a inflação com acurácia em horizontes longos para nortear a política monetária, o resultado encontrado pode ser decorrente de que as previsões no relatórios de inflação estejam condicionadas a cenários para taxa de juros que não são prováveis.

Alencar (2006) a partir das variáveis taxa básica de juros, taxa de câmbio, base monetária, produção física industrial e a taxa de desemprego e por meio dos modelos *Naïve*, ARIMA, ARCH, EGARCH, ADL - Curva de Phillips e VAR com fundamento econômico compara as modelagens a fim de apresentar as que possuem melhores previsões da inflação no curto prazo (até três meses à frente). O autor utilizou em sua análise o período de janeiro de 1999 a dezembro de 2004. Os resultados do trabalho foram que modelos com pouca ou nenhuma teoria econômica são mais eficazes na previsão da inflação do que os modelos amparados pela teoria econômica e com muitas variáveis incluídas nas regressões.

[3]O relatório FOCUS é um boletim semanal que resume as expectativas de mercado coletadas na semana anterior. O FOCUS traz a evolução gráfica das estatísticas calculadas e o comportamento semanal das previsões para índices de preços, atividade econômica, câmbio, taxa Selic, entre outros indicadores. As previsões são do mercado, não do BC.

Carvalho (2006) modelou a expectativa de inflação 12 meses à frente através das seguintes variáveis explicativas: política monetária, meta de inflação definida pelo Conselho Monetário Nacional (CMN) para os 12 meses seguintes, “risco país”, expectativa de inflação do período anterior, taxa de câmbio e da inflação corrente. O autor concluiu que as expectativas de inflação se ajustam gradualmente (efeito defasado) em função de choques nas variáveis explicativas. Apesar da relação entre a taxa de juros Selic e a inflação muitas vezes parecer ambígua, está clara a importância da política monetária como um sinalizador do comprometimento da autoridade monetária com a política de metas de inflação. Quanto a influência da taxa de câmbio como formadora de expectativas, é verificado que a desvalorização cambial acumulada em três períodos faz elevar a expectativa de inflação 12 meses à frente.

Chan (2009), para o período de setembro de 2008 a agosto de 2009, encontra resultados semelhantes àqueles de Alencar (2006). A autora ao avaliar as previsões de modelos de séries temporais univariados (*Naïve*, ARIMA e GARCH), estrutural (curva de Phillips) e multivariado (VAR), pela estatística RMSE e com horizontes de previsão de 1 mês e 1 trimestre. Com isso, demonstra que modelos simples, como o *Naïve* e o ARIMA, são mais eficazes na previsão da inflação de curto prazo do que os modelos de Curva de Phillips e VAR utilizado pelo BCB.

Lima e Alves (2011) não encontram evidências de que a média das previsões de mercado (FOCUS) tem habilidade preditiva superior a de modelos univariados AR no período amostral de maio de 2003 a maio de 2010. Com isso, encontraram resultados semelhantes a Lima e Céspedes (2006) que analisaram o período de janeiro de 2000 a abril de 2005.

Chernavsky (2011) compara as previsões de mercado com base no relatório FOCUS e de dois modelos univariados simples (*Random Walk* e SARIMA). O período analisado é de abril de 2000 a abril de 2010 no horizontes preditivos de um mês, um trimestre, um semestre e um ano. Quanto a inflação, as previsões de mercado (FOCUS) subestimaram as projeções da inflação. Além disso, os erros de previsões dos modelos lineares tendem a ser menores que os erros das previsões do relatório FOCUS em horizontes mais curtos, enquanto isto reverte no horizonte de um ano.

Caetano e Silva Jr. (2012) para o período de janeiro de 2002 a fevereiro de 2007 compararam modelos univariados (AR, ARMA e *Random Walk*) com as previsões do BCB e de vinte instituições do mercado que contribuem no relatório FOCUS nos horizontes de 1 mês a 12 meses. Pela comparação múltipla de previsões,

conforme Hansen (2005), os autores encontram resultados que corroboram a hipótese de que os modelos univariados apresentam menores erros de previsão em comparação às projeções de mercado e do BCB.

Os resultados encontrados indicaram que divergências nas expectativas do mercado existem e que se reduzem (aumentam) com a queda (subida) da inflação efetiva e que às vezes tendem a aumentar quando a inflação apresenta picos de alta ou de baixa. Através dos critérios de acurácia preditiva: RMSE, MSE (*mean square error*), MAE (*mean absolute error*) e, principalmente, com a aplicação do teste estatístico SPA[4] os autores encontram resultados que corroboram os trabalhos anteriormente citados. Os modelos univariados apresentaram maiores capacidades de previsão em comparação às projeções de mercado e do BCB.

Abreu (2015) no período de janeiro de 1996 a dezembro de 2013 utilizou-se de modelos univariados (Naïve, ARIMA, GARCH e UC-SV) e um modelo multivariado (VAR) e um modelo estrutural (curva de Phillips) para avaliar a acurácia das previsões a partir da estatística RMSE e pelo teste Dielbold-Mariano modificado proposto por Harvey, Leybourne e Newbold (1997). Os resultados indicam que os erros de previsão dos modelos diminuíram ao longo do tempo, o que corrobora a ideia de que as reduções na média e na volatilidade do nível de preços, decorrentes da implantação do regime de metas, contribuíram para aumentar a previsibilidade da inflação.

Adicionalmente, neste trabalho, a autora relata que algumas mudanças na capacidade preditiva ocorridas nos períodos mais recentes fornecem indícios de que alguns modelos, como o VAR(2), estejam aumentando a acurácia de suas previsões. O modelo VAR (2) é baseado em uma das especificações mais recentes utilizadas pelo Banco Central do Brasil, e isso pode sugerir que a inflação tem sido antecipada pelo BCB e suas previsões tem incorrido em menores erros.

Além disso, destaca que mesmo que um modelo produza previsões de inflação mais precisas do que outro, deve-se avaliar que pode não ser uma escolha ótima desconsiderar as previsões dos modelos com desempenho inferior. No caso em que um modelo de previsão que apresenta maior precisão é escolhido como preferido em detrimento de outro, há a possibilidade de se descartar previsões que poderiam

[4]O teste SPA, proposto por Hansen (2005), é um teste que pode ser usado para comparar performances de dois ou mais modelos de previsão. As previsões são avaliadas usando uma função de perda previamente especificada e a previsão do modelo “melhor” indica a menor perda esperada. Duas funções de perda foram previamente sugeridas pelo autor: “o erro quadrático médio (MSE) e erro médio absoluto (MAE)".

fornecer informações úteis sobre o futuro e que não estão contidas nas previsões do modelo preferido.

Para mais modelagens de previsão de inflação destacamos modelos estruturais baseados em curva de Phillips como proposto por Arruda, Ferreira e Castelar (2011); modelos puramente estatísticos como o de Carlos e Marçal (2013) e os indicadores antecedentes da inflação de Chauvet (2001) são os usados com frequência.

Apesar da discussão sobre a dinâmica e a previsibilidade da inflação no Brasil ser recente, parece haver indícios de que o processo ocorrido nos Estados Unidos, exposto na seção anterior, também tem ocorrido no Brasil. Dessa forma, é relevante avaliar se a redução da volatilidade e da taxa de inflação tem elevado o poder de previsão dos agentes, desde a adoção do regime de metas no Brasil. Além disso, é possível questionar se o uso de modelos estatísticos (simples), como os modelos *Naïve* ou autorregressivos, são capazes de gerar previsões de inflação mais acuradas do que as geradas por estruturais (com fundamentação econômica).

2.3 Programação por Metas

Na existência de mais de um modelo de previsão, espera-se que um modelo de previsão possua melhor performance que outro, ou seja, possua desempenho previsor mais acurado que os demais. O trabalho de Bates e Granger (1969) é um dos pioneiros no estudo de combinação de previsões, cujo princípio é a possibilidade de aumentar a precisão das previsões através da complementaridade obtida em cada previsão individual oriunda de diferentes métodos.

Ferreira, Bierens e Castelar (2005) consideram combinações simples de previsões oriundas de diferentes modelos e mostram que tais combinações de previsões geram resultados mais acurados do que modelos individuais. Ferreira e Palma (2015) demonstram que a combinação dinâmica de modelos (DMA), bem como a seleção dinâmica de modelos (DMS) melhoram significativamente previsão da taxa de inflação brasileira e superam diversos modelos concorrentes. Neste contexto, este trabalho analisará modelagens de previsões de inflação multivariado (VAR) em conjunto com a proposição de Bates e Granger (1969) de combinação linear de previsões.

A combinação linear de métodos preditivos é obtida pela ponderação das previsões de cada método individual por pesos determinados, na maioria das vezes, de forma a minimizar o erro quadrático médio (MSE) da previsão combinada. Contudo, o MSE é apenas uma das estatísticas capazes de ser utilizada para avaliar a qualidade do ajuste de um método de previsão. Outras estatísticas, usualmente empregadas com esta finalidade, são o MAPE (*mean absolute percentual error*) e o MAE (*mean absolute error*). Assim, neste trabalho, calculamos a combinação linear de previsões com pesos determinados mediante a otimização multiobjetivo MINIMAX (Ragsdale, 2010).

Segundo Jones e Mehrdad (2010), os trabalhos seminais mais formais de programação com objetivos múltiplos são de Charnes e Cooper (1961). Os autores buscavam uma forma de resolver problemas de programação linear que se apresentavam inviáveis devido a conflitos existentes entre as equações de restrição. A partir deste estudo foram desenvolvidos modelos para diversos tipos de programação multiobjetivo.

A programação multicritério ou multiobjetivo auxilia a tomada de decisão do gestor com múltiplos objetivos a articular suas preferências em presença de conflitos, rivalidades e incertezas de modo a decidir de maneira mais coerente com seus interesses (GOMES E MARANHÃO, 2008). Diversas são as aplicações e utilizações empírica deste tipo de programação com situações conflitantes.

Desta forma, estão disponíveis inúmeros métodos de tomada de decisão com objetivos múltiplos. A Programação por Metas, em inglês, *Goal Programming*, tem sido utilizada com frequência e se tornou objeto de estudo em diversas pesquisas por permitir diferentes abordagens (ERTUĞRUL e GUNES, 2007).

Segundo Aouni e Kettani (2001) a Programação por metas é o modelo mais conhecido de programação multicritério com crescente utilização e desenvolvimento teórico e em suas diversas aplicações práticas, todas bem sucedidas.

A Programação por Metas também pode ser vista como uma espécie de programação linear que permite estabelecer objetivos múltiplos, expressos como metas a serem atingidas (RAGSDALE, 2010). Segundo o autor, diversos problemas de decisão gerenciais podem ser modelados com maior acuidade utilizando metas ao invés de restrições. Geralmente estes problemas não possuem uma função objetivo explícita a ser minimizada ou maximizada, e sim metas que podem incluir variáveis flexíveis e restrições.

Com utilização de variáveis rígidas e flexíveis, através do estabelecimento de níveis de desvios com relação às metas, há grande avanço na modelagem e na análise de problemas de decisão nos quais existem vários objetivos, mesmo conflitantes e/ou incomensuráveis, a serem atingidos. Com isso, admite flexibilidade no nível de atingimento às metas, de forma que seja possível considerar mais de um cenário de acordo com os desvios e prioridades estabelecidas. Tal característica representa um diferencial para o agente encarregado de tomar decisões, devido à grande quantidade de fatores, interesses e variáveis envolvidas na maioria dos processos decisórios.

Uma importante característica da Programação por Metas é a de permitir a minimização de desvios em relação às suas metas, segundo prioridades previamente estabelecidas (LEE, KANG e CHANG, 2008). Alguns conceitos são fundamentais para a compreensão do modelo de Programação por Metas (MORAIS NETO, 1988):

- Objetivo: expressão que reflete o desejo do decisor, como maximização de lucro, minimização de custos, etc.;
- Nível de aspiração: valor associado ao nível de atingimento de um objetivo que se deseja alcançar;
- Meta: equação formada pela associação entre objetivo e nível de aspiração;
- Desvio da meta: é a diferença que poderá ocorrer entre o nível de atingimento alcançado para uma meta e o nível de atingimento inicialmente desejado. Portanto, podem existir desvios positivos (quando a meta é superada) ou negativos (quando a meta não é atingida).

Dentre os tipos de classificação da Programação por Metas, Jones e Mehrdad (2010) e Mirrazzavi, Jones e Tamiz (2001) destacam:

- Programação por Metas Ponderadas (*Weighted Goal Programming*): para cada desvio associado às metas é estabelecido um peso em função da importância relativa dada pelo decisor à meta. Para meta menos importante, cuja minimização de seus desvios é irrelevante, deve-se atribuir para o peso valor zero ou próximo de zero; caso contrário, deve-se atribuir um valor mais alto. Todas as metas ponderadas são consideradas simultaneamente. Para objetivos incomensuráveis, é possível estabelecer desvios percentuais para possibilitar a soma direta dos valores ponderados na função execução;
- Programação por Metas Lexicográficas (ou *Pre-Emptive Goal Programming*): Trata-se da minimização sequencial dos desvios previamente ordenados e

priorizados. Os desvios das metas com maior prioridade são minimizados ao máximo, para posteriormente serem considerados os desvios seguintes. Este método é utilizado quando o processo de tomada de decisão possui uma ordenação natural dos objetivos e na qual prevalece a comparação relativa entre eles.

- Programação por Metas Minimax: A terceira variante principal da programação de metas foi introduzida por Flavell (1976). É conhecida como *Chebyshev goal programming*, porque usa os meios subjacentes de Chebyshev para medir a distância. Ou seja, o desvio máximo de qualquer objetivo, em oposição à soma de todos os desvios, é minimizado. Por essa razão, a programação de metas de Chebyshev também é conhecida como programação de Metas Minimax.

Neste trabalho utilizamos a Programação por Metas Minimax uma vez que o decisor visa atingir um bom equilíbrio entre a consecução do conjunto de metas em oposição à abordagem lexicográfica que prioriza deliberadamente alguns objetivos em detrimento de outros ou a abordagem ponderada que escolhe o conjunto de valores de variáveis de decisão que juntos tornam a função de realização mais baixa, às vezes à custa de um valor muito fraco um ou dois dos objetivos.

A Programação por Metas Minimax também é a única variante principal que pode encontrar soluções ótimas para modelos lineares que não estão localizados em pontos extremos no espaço de decisão. Através da pesquisa realizada, foi possível constatar que a Programação por Metas Minimax possui grande espaço a percorrer na aplicação na tomada de decisão em modelos de previsão de inflação. Os resultados obtidos se mostram bastante satisfatórios, sendo os principais fatores relacionados à flexibilidade e robustez.

Quadro 1 – Resumo das literaturas internacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (continua)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Stockton e Glassman (1987)	Equação de Expectativa Racional com *Market Clearing* instantâneo Equação Monetarista Curva de Phillips com Expectativas Aumentadas Modelo ARIMA(4,1,0)	Logaritmo do nível dos preços agregados Logaritmo da Oferta de Moeda Expectativa do Log da Oferta de Moeda Logaritmo do Preço relativo da energia Logaritmo do Preço relativo de alimentos Logaritmo do Produto Real Logaritmo do Produto Potencial Log da Renda Nominal *Dummy* para período de controle de preços *Dummy* para período após controle de preços	1963T3 - 1982T4	8 trimestres
Mehra(1988)	Equação Monetarista Tradicional Curva de Phillips com Expectativas Aumentadas Modelo de Demanda por Moeda Modelo AR(1)	Índice de preços através do Deflator do PIB M1 M2 Gastos do Governo com emprego Preços relativos de Alimentos deflacionados pelos gastos com Consumos Pessoais Preços relativos de Energia deflacionados pelos gastos com Consumos Pessoais Produto Potencial PIB real Variável Custo de Oportunidade (Papéis a Juros de 4-6 meses menos a Variação no Estoque de Moeda)	1963T2 - 1977T1	8 trimestres
Jaditz and Sayers (1994)	Curva de Phillips Modelo VAR Modelo VECM Modelo AR(1)	Índice de preços ao consumidor Crescimento da Produção Industrial PPI (índice de preços ao produtor) Taxa de Títulos do Tesouro Americano (90 dias)	1967M01 - 1994M07	1 mês

Quadro 1 – Resumo das literaturas internacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (continuação)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Cecchetti (1995)	Curva de Phillips Regressão Simples	Índices de preços de commodities Preço do ouro Preço do petróleo Agregados monetários Taxas de juros Spreads da taxa de juros Índice de salários Taxa de câmbio ponderada pelo comércio Índice de horas trabalhadas semanais Índice de população empregada Utilização da capacidade Desemprego	1977M01 - 1994M07	3 meses 1 ano 2 anos 3 anos 4 anos
Stock e Watson (1999)	Curva de Phillips	168 indicadores econômicos (85 associados a atividade da economia real)	1959M01 - 1997M09	12 meses
Cecchetti, Chu e Steindel (2000)	Modelo de Indicadores Defasados Modelo AR	19 indicadores associados a preços de *commodities*, medidas do mercado financeiro e medidas de atividade econômica real.	1975T1 – 1996T4	4 trimestres
Atkeson e Ohanian(2001)	Curva de Phillips NAIRU Modelo Naive	85 indicadores mensais de atividade econômica	1967M03 – 2000M10	4 trimestres
Fisher, Liu e Zhou (2002)	Modelo Naive Curva de Phillips tradicional Curva de Phillips baseada no índice Nacional de Atividade do Chicago Fed (CFNAI) Curva de Phillips pela modelagem Stock e Watson (1999).	154 séries de dados, incluindo a produção, situação do mercado de trabalho, consumo das famílias, inventários e estoques, vendas, compras, mercado financeiro, oferta de moeda e dados de preços.	1967M01 – 2000M12	12 meses 24 meses

Quadro 1 – Resumo das literaturas internacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (conclusão)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Stock e Watson (2003)	Modelo AR Modelo Naive de Atkeson e Ohanian(2001) *Random Walk* Curva de Phillips *backward-looking* com inclusão de preços de ativos	43 séries incluindo preços de ativos do Mercado Financeiro, Indicadores de Atividade Econômica, Salários, Preços de bens e *commodities,* Moeda e Agregados monetários	1959T1 – 1999T4	2 trimestres 4 trimestres 8 trimestres
Orphanides e Van Norden (2005)	Modelo AR Curva de Phillips com hiato do produto em tempo real	Índice de preços ao consumidor, Hiato do Produto (*ex-ante* e *ex-post*)	1965T1– 2003T3	4 trimestres
Stock e Watson (2007)	Modelo AR Modelo Naïve Curva de Phillips *backward-looking* do tipo Modelo UC-SV *(Unobserved Component with Stochastic Volatility)*	Índice de preços do PIB (inflação), Taxa de desemprego, Logaritmo do PIB real, Taxa de utilização da capacidade, Licenças de construção, Índice Nacional de Atividade do Fed de Chicago (CFNAI)	1960T1– 2004T4	1 trimestre 2 trimestres 4 trimestres 8 trimestres
Cecchetti et al. (2007)	Modelo UC-SV de Stock e Watson (2007) Modelo AR *time-varying*	As variáveis dividem-se entre as que possuem tendência estável (Abertura Comercial, Abertura Financeira, Envolvimento Sindical, Percentual de Serviços no Valor Agregado, Percentual da Industrial no Valor Agregado) e as que possuem outros desenvolvimentos (Choque do Petróleo, Preço de Petróleo e *Commodities*, Rigidez Fiscal, Regime Cambial, Percentual de Mão de obra empregada, Dias perdidos com Greves, Tendência de Produtividade, Taxa de desemprego, Expectativa de Inflação e Rentabilidade de títulos públicos.	1970T1 – 2006T4	12 trimestres
Hall e Jääskelä (2011)	Modelo UC-SV Modelo M-UC-SV (versão modificada de Stock e Watson (2007) Modelo Naïve de Atkeson e Ohanian(2001) além do Modelo Naïve	Índice de Preços ao Consumidor (consumidores urbanos) convertido para uma frequência trimestral	1960T1 – 2008T4	8 trimestres

Fonte**:** O autor, 2019.

Quadro 2– Resumo das literaturas nacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (continua)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Lima e Céspedes (2006)	Modelos AR (*lags* 1 até 5) Modelos ARMA	Diferença do logaritmo natural do IPCA mensal Taxa de Inflação Acumulada (3, 6, 9 e 12 meses) Previsões da taxa mensal de inflação do FOCUS (mês corrente e subsequentes) Previsões da taxa anual de inflação do FOCUS (mês corrente e subsequentes) Previsões da taxa de inflação mensal do Relatório de Inflação do BCB (à taxa de juros constantes e à taxa de decidida na última reunião do COPOM) Previsões da taxa de inflação anual do Relatório de Inflação do BCB (à taxa de juros constantes e à taxa de decidida na última reunião do COPOM)	2000M01 – 2005M04	1 à 9 meses
Alencar (2006)	Modelo Naïve Modelo ARIMA(1,1,5) Modelo ARCH Modelo EGARCH Curva de Phillips Modificada (Modelo ADL) Modelo VAR	Índice de preços ao Consumidor amplo (IPCA) Taxa Selic (*Overnight*) Base Monetária Produção Física Industrial Média da Taxa de câmbio comercial Taxa de desemprego da região metropolitana do estado de São Paulo	1999M01 – 2004M12	1 mês 2 meses 3 meses
Carvalho (2006)	Modelo de pequena escala de Svensson (2000)	Taxa nominal de juros Selic (efetiva), Meta de inflação para os próximos 12 meses Logaritmo natural do “risco país” medido pelo EMBI+ (*Emerging Markets Bond Index Plus*) Taxa de inflação (IPCA) mensal anualizada; Logaritmo natural da taxa de câmbio nominal Hiato do produto Gasto primário do Governo Central com custeio e capital (deflacionado pelo IPCA) Taxa real de juros ex ante (swap de 180 dias deflacionado pela expectativa de Inflação seis meses à frente) Taxa real de câmbio *Dummy* para o período do racionamento de energia	2000M01 – 2005M12	12 meses

Quadro 2 – Resumo das literaturas nacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (continuação)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Chan (2009)	Modelo Naïve Modelo ARIMA(1,1,4) Modelo GARCH Curva de Phillips Modelo VAR	Índice de Preços ao consumidor amplo (IPCA) Produção Industrial, Expectativa de Inflação dos agentes privados, Taxa Selic Média da Taxa de câmbio comercial Taxa de desemprego da região metropolitana do estado de São Paulo, Utilização de Capacidade da Indústria (NUCI): medida pela Confederação Nacional da Indústria	1999M01 – 2009M09	1 mês 1 trimestre (dentro da amostra)
Lima e Alves (2011)	Modelo AR(1) Modelo AR(3) com quatro intervenções para *outliers* Modelo BAR(3), *Bayesian Auto-Regression* de ordem 3	Índice de Preços ao consumidor amplo (IPCA) mensal e acumulada (3, 6, 9 e 12 meses) Expectativas do mercado, a respeito da taxa de inflação, são obtidas por meio do (FOCUS)	2003M05 – 2010M05	1 à 12 meses
Chernavsky (2011)	*Random Walk* tanto para o IGP-M quanto para o IPCA Modelo ARIMA(1,6) para IGP-M Modelo SARIMA(1,7) para o IPCA	Índice Nacional de Preços ao Consumidor Amplo (IPCA) mensal Índice Geral de Preços de Mercado (IGPM) mensal PIB (Produto Interno Bruto a preços de mercado) trimestral, Produção Física Industrial mensal Taxa de Câmbio, Conta Corrente mensal, Exportações mensal, Investimento Estrangeiro Direto mensal, Necessidades de Financiamento do Setor Público, primário com desvalorização cambial mensal, Dívida Total do Setor Público líquida mensal	2000M04 – 2009M12	1,3,6 e 12 meses 1,2,4 e 8 trimestres
Caetano e Silva Jr. (2012)	Modelo AR(1) Modelo AR(2) Modelo SAR (1) Modelo ARMA(2,1) Modelo ARMA(3,1) Modelo SARMA(5,3) *Random Walk*	Índice de Preços ao consumidor amplo (IPCA) mensal e acumulada (3, 6, 9 e 12 meses) Expectativas do mercado, a respeito da taxa de inflação, são obtidas por meio do (FOCUS) Previsões da taxa de inflação do Relatório de Inflação do BCB (à taxa de juros constantes e à taxa de decidida na última reunião do COPOM)	2002M01 – 2007M02	1 mês 12 meses

Quadro 2 – Resumo das literaturas nacionais: autoria, modelos, variáveis de análise, período de análise e horizonte preditivo (conclusão)

AUTORIA	MODELOS	VARIÁVEIS	PERÍODO	HORIZONTE
Abreu (2015)	Modelo Naïve Modelo AR(1) Modelo GARCH(1,1) Modelo VAR(2) Curva de Phillips	Índice de Preços ao consumidor amplo (IPCA) Hiato do produto, Média da Taxa de câmbio comercial, M1, Taxa Selic Produção Física Industrial mensal	1996M01 - 2013M12	12 meses

Fonte: O autor, 2019.

3 METODOLOGIA

Este capítulo está dividido em 3 seções, onde são apresentadas a metodologia utilizada neste trabalho assim como as variáveis de análise. As seções foram divididas conforme a seguir: 3.1Modelos de Vetores Autorregressivos, são apresentados conforme introduzido por Sims(1980) em seu trabalho seminal nos anos 80 que propôs esta modelagem e como o mesmo se estruturará nesta dissertação além dos teste estatísticos utilizados; 3.2 Previsão através de Modelos de Vetores Autorregressivos é apresentado o modelo pelo qual obtém-se a previsão de cada horizonte de previsão de forma geral e, mais especificamente, o modelo utilizado neste trabalho, bem como as características a serem destacadas; Na última seção, 3.3 Combinação de Previsões, Otimização MINIMAX e Métodos de Comparação preditiva, apresentamos como combinaremos as previsões individuais pelo método de otimização multiobjetivo MINIMAX, além de como comparamos o desempenho preditivo dos modelos.

3.1 Modelos de Vetores Autorregressivos

O modelo de Vetores Autorregressivo (VAR) apresentado por Sims (1980) tinha como restrições econômicas somente a escolha das variáveis e das defasagens. Os critérios para a seleção de modelos são meramente estatísticos. Ainda que a escolha das variáveis relevantes dependa do problema e do modelo que o autor acredite existir em funcionamento, a liberdade admitida para essa construção passou a preponderar (HOLLAUER et al. 2006). Com isso, estes modelos são ditos ateóricos em termos econômicos. O que em nosso entendimento é um diferencial na medida que não estaria “poluído” com viés ideológico de alguma escola de pensamento. Desde então, devido ao alto grau de precisão relativa a outros modelos para o curto prazo, os VAR servem como balizador para a projeção da trajetória de inflação (LIMA; ARAÚJO; SILVA, 2011) não apenas do Brasil mas de diversos países, conforme já informado neste trabalho.

Por meio do modelo de vetores autorregressivos (VAR) podemos analisar ao mesmo tempo diversas variáveis econômicas. Em geral, expressa-se um modelo autorregressivo de ordem *p* através de um vetor com *n* variáveis endógenas, X_t, interconectadas por meio de uma matriz *A*, conforme a Equação (1):

$$AX_t = \beta_0 + \sum_{i=1}^{p} \beta_i X_{t-i} + \beta\varepsilon_t, \qquad (1)$$

Admitindo-se que:

- A é uma matriz *n* x *n* que define as restrições contemporâneas entre as variáveis que constituem o vetor *n* x 1 (X_t);
- β_0 é um vetor de constantes *n*x 1;
- β_i são matrizes *n* x *n*;
- β é uma matriz diagonal *n* x *n* de desvio padrão; e
- ε_t é um vetor *n* x 1 de perturbações aleatórias não correlacionadas entre si contemporaneamente e temporalmente.

Devido a endogeneidade das variáveis, normalmente, estima-se este modelo em sua forma reduzida:

$$X_t = A^{-1}\beta_0 + \sum_{i=1}^{p} A^{-1}\beta_i X_{t-i} + A^{-1}\beta\varepsilon_t$$

$$X_t = \Phi_0 + \sum_{i=1}^{p} \Phi_i X_{t-i} + e_t$$

Onde:

$$\Phi_0 = A^{-1}\beta_i \text{, sendo } i = 0,1,\ldots,p \qquad \text{e} \beta\varepsilon_t \equiv Ae_t$$

Nos modelos VAR as variáveis explicativas e explicadas são endógenas, sendo todas apresentadas como resultantes de suas defasagens (*lags*) e das defasagens das demais variáveis do modelo, sendo que todas as variáveis do modelo possuem a mesma ordem de defasagem. No entanto, como somente o lado direito da equação conterá variáveis defasadas, não haverá simultaneidade na modelagem. O que se espera dos modelos VAR é que apresenta a trajetória das variáveis endógenas dado um choque estrutural. A estimação do modelo é feita com base no método de mínimos quadrados ordinários (MQO).

No modelos VAR, um choque sobre a *i*-ésima variável afeta não apenas diretamente a *i*-ésima variável, mas também é transmitida para todas as outras variáveis endógenas através da estrutura dinâmica (defasagens) do VAR. A função de resposta ao impulso (FIR) descreve a trajetória do efeito de um choque de uma só vez para uma das inovações sobre valores atuais e futuros das variáveis endógenas.

Se as inovações são contemporaneamente não correlacionadas, a interpretação da resposta ao impulso é direta. A *i*-ésima inovação é simplesmente um choque para a *i*-ésima variável endógena. As inovações, no entanto, são geralmente correlacionadas e podem ser vistas como tendo um componente comum que não pode ser associado a uma variável específica. Para interpretar os impulsos, é comum aplicar uma transformação às inovações para que elas se tornem não correlacionadas. Sims(1980) sugere um sistema recursivo para identificar o modelo, ou seja, propõe que alguns coeficientes sejam zero. Os coeficientes zerados são definidos com base na teoria econômica. Com um vetor *n* de variáveis endógenas é possível generalizar uma modelagem, ou seja uma maneira de decompor os resíduos conhecida como decomposição de Cholesky. Com isso, será possível escrever o VAR como um vetor de médias móveis infinito MA(∞). Em consequência, um incremento unitário (impulso) na inovação da *j*-ésima variável, no tempo *t*, gera uma resposta sobre a *i*-ésima variável, mantendo as demais variáveis constante. A função resposta ao impulso demonstram a resposta às inovações em uma variável a um impacto de uma unidade de erro padrão sobre cada variável.

Como base para a determinação de quais variáveis explicativas seriam utilizadas neste trabalho foi utilizado o último relatório de inflação do BCB que detalhou a modelagem, variáveis e defasagens utilizada para estimar a inflação pela modelagem VAR (BCB, 2012). No entanto, este trabalho não pretende reproduzir *ipsis litteris* os modelos utilizados pelo BCB mas posicionar-se o mais cerca possível deles a fim de que os resultados deste trabalho possam ser úteis para aquela instituição e demais interessados no assunto.

O quadro 3 apresenta os modelos VAR estimados neste trabalho além das variáveis utilizadas em cada um deles e o deflator de juros utilizado. O detalhamento das séries e dados utilizados encontra-se no capítulo 4.

Quadro 3– Modelagens VAR utilizadas para estimação e previsão da inflação

Modelo	Var. dependente	Var. explicativas	Juros reais (Deflator)
VAR I	IPCA	Câmbio, juros reais	IGP-M *ex-post*
VAR II	IPCA	M4/Base Monetária, câmbio, juros reais	IPCA *ex-post*
VAR III	IPCA	Produção Industrial, juros reais	IGP-M *ex-post*
VAR IV	IPCA	M1, juros reais	IGP-M *ex-post*

Fonte**:** O autor, 2019.

Conforme Bueno(2015), a estacionaridade é que permitirá proceder as inferências sobre os parâmetros estimados com base na realização de um processo estocástico. Logo, para as séries históricas utilizadas, tanto em nível quanto em primeira diferença, foi verificado se eram estacionárias utilizando-se três testes de raiz unitária: Dickey Fuller Aumentado (sigla em inglês, ADF), Phillips-Perron e KPSS.

Apenas pela verificação visual de uma série temporal, não podemos afirmar com certeza se uma tendência é estocástica ou determinística. Segundo Bueno (2015, p.119), com base nisso desenvolveu-se o teste ADF quando estamos supondo que o erro é um processo estacionário qualquer. Em termos práticos, para realizar o teste ADF são introduzidas tantas variáveis autorregressivas no modelo quanto forem necessárias até que o teste de resíduos não rejeite a hipótese de que se trata de um ruído branco. Logo, as variáveis serão não estacionárias se a média e a variância alterarem ao longo do tempo. Neste trabalho, optamos por incluir uma constante e uma tendência de tempo constante e linear, na regressão de teste. Ao executar o teste com uma tendência constante e linear estamos realizando um teste de especificação mais geral. No entanto, sabemos que a inclusão de regressores irrelevantes na regressão reduz o poder do teste de rejeitar a hipótese nula de raiz unitária.

Os Testes Phillips-Perron (PP) e KPSS foram usados para trazer robustez aos resultados, ou seja, para que corroborem os resultados obtidos pelos testes de raiz unitária ADF, uma vez que possuem metodologias diferentes daquele do ADF.

Ao realizarmos os 3 testes de raiz unitária das séries em nível, foi detectado que praticamente todas as séries não eram estacionárias para um nível de significância de 5%. Desta forma, decidiu-se por trabalhar com as séries em primeira diferença, visto que com sob a nova condição todas eram estacionárias para um nível de significância de 1% o que nos permite realiza as inferências sobre os parâmetros estimados. Para uma análise sobre os resultados dos testes verificar a seção 4.1.

A descoberta de que muitas séries temporais macroeconômicas podem conter uma raiz unitária estimulou o desenvolvimento da teoria da análise de séries temporais não estacionárias. Engle e Granger (1987) apontaram que uma combinação linear de duas ou mais séries não estacionárias pode ser estacionária. Quando isto ocorre, dizemos que as séries temporais não estacionárias são cointegradas.

Na presença de cointegração, os métodos de correção de erro de vetor (VEC) ou de regressão não estacionária podem ser usados para estimar a equação de cointegração. A combinação linear estacionária é chamada de equação de cointegração e pode ser interpretada como uma relação de equilíbrio de longo prazo entre as variáveis. A inclusão de tais relações de longo prazo tem sido proveitosa no trabalho de previsão, como sugerem diversos estudos (CLEMENTS; HENDRY, 1995; ENGLE; YOO, 1987; LIN; TSAT, 1996). Para uma análise sobre os resultados dos testes de cointegração realizados neste trabalho verificar o Anexo estatístico.

Como forma de verificar se a série tem distribuição normal, baseada em diferenças entre assimetria e curtose da distribuição da série em relação à normal, utilizamos o Teste Jarque-Bera (JB). Este teste é conhecido por ter boas propriedades para verificar normalidade, claro e simples de calcular sendo muito utilizado no contexto de regressão em econometria. Uma limitação que possui é somente poder ser utilizado na verificação de normalidade.

O teste JB utiliza como parâmetros os coeficientes de curtose e assimetria (que na distribuição normal são 3 e 0, respectivamente). Com isso, podemos verificar se a série tem distribuição aproximadamente normal. Uma vez que a existência de desvios muitos grandes, i.e., uma curtose acima de 4 e assimetria acima de 1 invalidaria nossos erros-padrão e intervalos de confiança.

Com relação as defasagens das variáveis usadas neste trabalho e apesar do BCB divulgar quais as defasagens utiliza, decidiu-se por realizar os testes a seguir a fim de verificarmos a melhor especificação dos modelos VAR:

- Seleção de ordem de defasagens ou *Lag Order Selection Criteria*: Este teste é utilizado para definir o número de defasagens ou a ordem p do modelo. Inicialmente, é estabelecida a ordem máxima ($m_{áx.}$) do teste a ser realizado. No caso deste trabalho foi definida como $p_{máx} = 12$, i.e., estabeleceu-se que deveria ser testado até a defasagem 12 quais defasagens obteriam resíduos brancos entre todas as variáveis do modelo até 12 passos. No entanto, é sabido que a conciliação de ruídos brancos (w*hite noises*) entre todas as variáveis não é

trivial, logo nos resultados deste trabalho foram apresentadas as defasagens necessárias para obter resíduos brancos para todas as variáveis endógenas em cada um dos modelos gerados. Apesar dos resultados deste teste, decidiu-se por estimar modelos com ordem I(1), I(2) e I(3). Ou seja, com base nos critérios de parcimônia e bom senso necessário a qualquer pesquisador na escolha dos *lags,* a fim de evitar a sobreparametrização, esperamos que o modelo seja bom previsor da inflação. Isto porque um modelo pode ser bem ajustado a série temporal mas suas previsões podem ser pouco acuradas quando analisadas fora-da-amostra, isto que queremos evitar.

- Teste do *Graph Root*: A fim de conferir a estabilidade, ou seja, do VAR estimado, com este teste podemos verificar se todas as raízes do polinômio estão dentro do círculo unitário, ou seja, se, em módulo, a raízes são menores do que 1. Se isso ocorrer, a modelagem é estável e, em conjunto, todas as séries são estacionárias.
- Critérios de informação de Akaike (AIC) e Critério de Schwarz (SC): Os testes de critério de informação AIC e SC são utilizados para selecionar modelos VAR assim como para determinar o comprimento das defasagens. O melhor resultado esperado para estes testes é que eles sejam os menores valores possíveis. De acordo com Hollauer (2006, p. 11), esses testes de critérios objetivam a parcimônia na determinação do número de defasagens do modelos, impondo penalidades pelo número de regressores. No entanto, a adequação cresça com a redução da soma dos quadrados dos resíduos em consequência do número de variáveis incluídas e com o aumento da ordem dos *lags*, estes testes de critérios irão penalizam a escolha por mais defasagens. O que diferencia os diversos critérios, além da origem, é o quão forte penalizam um modelo por ter mais defasagens do que necessitava. Com isso, é possível que os testes de critério escolham modelos distintos.

Um segundo problema está no fato dos teste serem definidos dentro da amostra. Ou seja, apenas consideram a série histórica sem qualquer inclusão de informação relativa a previsão. Em teoria, não podemos afirmar que o melhor modelo dentro da amostra (*in-sample*) é o de melhor acurácia preditiva fora da amostra (*out-of-sample*). Logo, apenas a pesquisa empírica da série temporal servirá de orientação. No entanto, os testes auxiliam, dentre outras coisas, na inclusão ou não de variáveis.

Ainda quanto a especificação dos modelos VAR, segundo Bueno (2015, p.223), a fim de conhecer se uma variável é capaz de prever a outra e em que condições utilizou-se o teste de causalidade de Granger. Ou seja, podemos verificar se as defasagens de uma variável estão dentro da equação de outra variável. Em termos gerais, supondo uma variável *y* que é dita ser causada por Granger pela variável *z*, se *z* ajuda na previsão de *y*; ou de maneira equivalente, se os coeficientes defasados de *z* são estatisticamente significativos. Note que o teste de causalidade de Granger pode ser testado em ambos sentidos, i.e., *z* causa Granger *y* e *y* causa Granger *z*.

Em termos práticos os resultados obtidos pela causalidade de Granger nos revela qual variável precede, qual vem como causa da que a precede e se as variáveis são contemporâneas. Como descreveram Pimenta e Higuchi (2002), o teste mostra uma série que provoca a outra, se os valores defasados preveem significativamente a outra série, enquanto que a relação inversa não se verifica significativamente. Na ocorrência de causalidade de Granger entre duas séries estaremos visualizando que um modelo VAR é uma boa metodologia para modelar e projetar as séries inter-relacionadas.

Neste trabalho, realizamos testes de causalidade de Granger para a relação entre as variáveis de cada modelagem (VAR I até VAR IV). Os resultados destes testes deverão informar se as variáveis explicativas são preditores significativos do IPCA (variável explicada). Isso nos demonstra se uma variável explicativa causa o IPCA de modo “Granger”. Os resultados de cada modelo e variáveis estão descritos no capítulo 4.Após conclusão da especificação dos modelos bem como os testes de estacionaridade das séries utilizadas, apresentamos adiante a metodologia de previsão empregada a partir dos modelos VAR.

3.2 Previsão através de Modelos de Vetores Autorregressivos

A partir dos modelos VAR realizar previsões não possui qualquer complexidade. Para realizar a previsão de um período à frente, o vetor de variáveis

endógenas ($\hat{Z}_{t+1}$) é obtido pela substituição de valores passados e correntes nos períodos *t* a *t + 1-p* na equação (2):

$$\hat{Z}_{t+1} = A_1 Z_t + A_2 Z_{t-1} + \cdots + A_p Z_{t+1-p} \quad (2)$$

Da mesma maneira, para dois períodos à frente para o vetor de variáveis ($\hat{Z}_{t+2}$) é obtido substituindo ($\hat{Z}_{t+1}$) e os valores observados das variáveis nos períodos *t* para *t + 2-p* na equação (3):

$$\hat{Z}_{t+2} = A_1 \hat{Z}_{t+1} + A_2 Z_{t-1} + \cdots + A_p Z_{t+1-p} \quad (3)$$

Deste modo, as previsões geradas pelo VAR são capazes de projetar para frente as correlações estatísticas anteriores entre as variáveis no sistema. Com isso, estamos supondo que os modelos incorporam que essas correlações continuarão a se manter no período de previsão. Cabe aqui uma comparação com as previsões oriundas de modelos estruturais tradicionais, posto que naqueles modelos as previsões normalmente serão condicionada a hipóteses sobre o comportamento futuro de variáveis consideradas exógena (política fiscal, por exemplo). As previsões de VAR-clássico, utilizada neste trabalho, não carecem de hipóteses sejam elas ad hoc ou não. Pelos modelos VAR, cada uma das variáveis são tratadas como endógenas onde o sistema gera a previsão sem o direcionamento prévio de hipóteses. Com isso, podemos dizer que as previsões básicas de VAR são incondicionais.

As previsões de VAR são úteis tanto individualmente quanto combinadas a outros métodos ou modelagens de previsões. No entanto, as previsões por meio de modelos VAR estão sujeitas a críticas. Além de estarem suscetíveis a crítica de Lucas e, em termos gerais, podem apresentar baixo desempenho após quebras estruturais. No entanto, alguns modelos macroeconométricos tradicionais também possam ser afetados por estes problemas. Clements e Hendry (1995) argumentam que os modelos VAR tendem a ser menos afetados por quebras estruturais do que modelos estruturais, pois são muitas vezes formulados nas primeiras diferenças das variáveis, o que as torna menos vulneráveis. No entanto, este trabalho irá realizar previsões de 12, 6 e 3 passos à frente o que torna-se mais difícil de apresentar quebra estrutural, além de que as variáveis foram definidas como em primeira diferença.

Além disso, uma segunda crítica aos modelos VAR sugere que a inclusão de muitas defasagens ou muitas variáveis (*overfitting* ou sobreparametrização) podem levar as previsões a ter um desempenho com baixa acurácia, embora o modelo ajuste-se bem aos dados no período de estimativa. Isso ocorre se os *lags* das variáveis da modelagem obtém relações não sistemáticas entre as variáveis (isto é, relações espúrias ou "ruído" nos dados), bem como as relações sistemáticas (ou seja, robustas). Contudo, se o conjunto de variáveis e comprimentos de defasagem forem mantidos relativamente pequenos (resultante de considerações implicitamente teóricas) espera-se que as previsões derivadas de VAR sejam imprecisa. Por este motivo as previsões com base nos modelos VAR geradas neste trabalho serão apenas utilizadas para produzir previsões de curto prazo (12, 6 e 3 meses à frente) uma vez que para horizontes mais longos, o desempenho de previsão dos VAR deteriora-se rapidamente.

Como Bernanke(1990), Thoma e Gray(1994) e Jordan(2003), dentre outros; consideramos apenas as previsões fora da amostra. Segundo os autores, os modelos de previsão são avaliados como úteis na medida que são capazes de prever com dados fora da amostra. Isto porque para previsões dentro da amostra mais acuradas não estão diretamente associadas a melhores capacidades de gerar previsões fora da amostra. Desta maneira, neste trabalho, decidiu-se por calcular todas as previsões como fora da amostra.

Conforme o método que será apresentado na seção a seguir, cada uma das modelagens VAR geradas individualmente serão combinadas.

3.3 Combinação de Previsões, Otimização MINIMAX e Métodos de Comparação preditiva

Este trabalho não se aterá a um modelo VAR em particular para gerar previsões. Como será visto adiante, o procedimento de seleção de modelo não será realizado *ex-ante.* Ou seja, os testes citados na seção 3.2 não serão os únicos instrumentos de escolha dos modelos para previsão. Esta seção é dedicada a uma

descrição do procedimento combinação de previsões a fim de contribuir na interpretação dos resultados apresentados no capítulo 4.

O procedimento adotado neste trabalho considera que as previsões de vários VAR são combinadas para produzir uma previsão final. Com isso, é esperado que a precisão das previsões pode ser melhorada pela combinação de várias previsões. Diversas são as razões para efetuar a combinação de modelos no intuito de gerar previsões de performance superior (FANG, 2003).

A primeira seria melhoria proveniente de um efeito de diversificação dos erros. Ou seja, se os erros de previsão individuais de diferentes VAR não estiverem perfeitamente correlacionados, a variação de previsão de uma combinação de previsões será menor do que a média prevista variância das previsões individuais. A segunda razão seria que a combinação de previsões também reduz o problema da incerteza do modelo. Ao combinarmos previsões de diferentes modelos, a possibilidade de um dos modelos estar mal especificado diminui se compararmos com a previsão oriunda de apenas um único modelo. Normalmente, combinando previsões de modelos com variáveis diferentes, a informação pode ser agregada. Este argumento é particularmente importante para o caso dos modelos VAR, porque eles são especificados com um número limitado de variáveis. Ademais, modelos com menos variáveis e *lags* combinados possuem performance preditiva superior, até porque a sobreparametrização dos modelos VAR deteriora a sua performance preditiva. Nesse sentido, a combinação pode ser usada para examinar um número maior de variáveis, sem que seja necessário sobreparametrizar algum VAR em específico.

Quando combina-se várias previsões para gerar uma única previsão, diversos são os esquemas de ponderação que podem ser utilizados. O procedimento de previsão VAR adotado neste trabalho será de dois tipos. No primeiro, que chamaremos de abordagem tradicional, Bates e Granger (1969) propuseram a combinação linear de duas previsões objetivas não tendenciosas oriundas de dois modelos estatísticos clássicos conforme apresentado na equação 4 a seguir:

$$\hat{y}_{CL,t} = \left[\hat{y}_{1,t} \times \hat{p}_1\right] + \left[\hat{y}_{2,t} \times \hat{p}_2\right] \qquad (4)$$

onde a previsão combinada $\hat{y}_{CL,t}$ é dada pela média ponderada das previsões do modelo 1 ($\hat{y}_{1,t}$) e do modelo 2 ($\hat{y}_{2,t}$), em que os pesos $\hat{p}_1$ e $\hat{p}_2$ somam um e são

determinados de forma a minimizar a estatística MSE (*Mean Square Error*) esta medida de avaliar e comparar a performance de modelos será usada para definir o peso que cada previsão individual deverá assumir ao serem combinadas.

Newbold e Granger (1974) mantendo as suposições de Bates e Granger (1969) concluíram que, em regra, as previsões combinadas são mais acuradas ao serem combinados três métodos estatísticos clássicos. Winkler e Makridakis (1983) analisaram modelos combinados três a três entre dez modelos estatísticos de previsão e os resultados confirmaram as conclusões de Newbold e Granger (1974). De acordo com Aiolfi e Timmermann (2006); De Luca e Carfora (2014); Faria e Mubwandarikwa (2008) e Stock e Watson (2004); as combinações de previsões podem promover ganho preditivo fora da amostra (*out of sample*).

Assim, neste trabalho, a previsão combinada, para cada instante *t*, pode ser interpretada como a média ponderada das previsões destes métodos individuais, onde a soma dos pesos $\hat{p}_{VAR\ I}$,$\hat{p}_{VAR\ II}$,$\hat{p}_{VAR\ III}$ e $\hat{p}_{VAR\ IV}$é igual a um, e é definida conforme a equação 5:

$$\hat{y}_{CL,t} = [VAR\ I_t \times \hat{p}_{VAR\ I}] + [VAR\ II_t \times \hat{p}_{VAR\ II}] + [VAR\ III_t \times \hat{p}_{VAR\ III}] + [VAR\ IV_t \times \hat{p}_{VAR\ IV}] \quad (5)$$

Logo, quando combinarmos previsões pela abordagem tradicional os pesos serão definidos de forma a minimizar a estatística MSE. Contudo, a avaliação da qualidade do ajuste de um modelo não se resume ao erro quadrático médio, pois existem outras estatísticas como, por exemplo, o erro médio absoluto (MAE) e erro médio percentual absoluto (MAPE). Assim, propõe-se determinar os pesos $\hat{p}_{VAR\ I}$,$\hat{p}_{VAR\ II}$,$\hat{p}_{VAR\ III}$ e $\hat{p}_{VAR\ IV}$de maneira a minimizar, simultaneamente, as estatísticas MSE, MAE e MAPE, mediante otimização multiobjetivo com abordagem de programação por metas. Portanto, quando combinarmos previsões desta forma chamaremos de abordagem MINIMAX.

Neste trabalho, além da abordagem tradicional, para busca de soluções ótimas com relação aos pesos, utilizamos o procedimento de programação matemática envolvendo mais de uma função objetivo (otimização multiobjetivo). Logo, na combinação linear das previsões, os pesos $\hat{p}_{VAR\ I}$,$\hat{p}_{VAR\ II}$,$\hat{p}_{VAR\ III}$ e $\hat{p}_{VAR\ IV}$ serão as variáveis de decisão e as estatísticas MSE, MAE e MAPE serão as funções objetivo a serem minimizadas, simultaneamente. Ou seja, os pesos ótimos são tais que

assumem valores que minimizam as estatísticas MSE, MAPE e MAE simultaneamente.

Uma das possíveis metodologia de otimização multiobjetivo denomina-se programação por metas ou em inglês *Goal Programming*, que consiste em identificar a solução ótima que minimiza os desvios entre os valores das funções objetivos e suas respectivas metas pré-definidas (RAGSDALE, 2010). Esta técnica requer um procedimento de solução iterativa no qual o tomador de decisão investiga uma série de soluções viáveis a fim de encontrar a mais satisfatória. O objetivo da programação por metas pode ser definido como a soma ponderada dos desvios percentuais absolutos conforme a equação (6).

$$Min \;\; \omega_{MAPE} \frac{MAPE - Meta_{MAPE}}{Meta_{MAPE}} + \omega_{MAE} \frac{MAE - Meta_{MAE}}{Meta_{MAE}} + \omega_{MSE} \frac{MSE - Meta_{MSE}}{Meta_{MSE}} \qquad (6)$$

Os coeficientes (pesos) ω_{MAPE}, ω_{MAE} e ω_{MSE}são constantes que podem ser fixadas pelo decisor (atribuindo preferências distintas em relação às estatísticas de ajuste MAPE, MAE e MSE) ou interpretadas como variáveis de decisão (devendo-se, assim, encontrar os seus valores ótimos). As metas indicadas na função objetivo são valores de referência obtidos, comumente, por otimização individual de cada função objetivo.

As metas são definidas com o auxílio da abordagem tradicional da combinação linear de previsões. Assim, o MSE resultante da combinação linear ótima é a meta a ser alcançada pelo objetivo MSE no PPM multiobjetivo. Da mesma forma, a meta do MAE corresponde ao MAE resultante da abordagem tradicional de combinação linear, porém tendo como critério a minimização do MAE e não mais do MSE. Por sua vez, a meta para o MAPE é obtida por meio da combinação linear de previsões que minimiza o MAPE. Em outras palavras, a abordagem tradicional foi aplicada três vezes, sendo que em cada vez se considerou um critério (estatística) diferente.

Um problema de programação matemática multiobjetivo também pode ser resolvido por otimização MINIMAX (RAGSDALE, 2010) com programação por metas, de forma que uma função objetivo Q impõe restrições aos desvios relativos entre as estatísticas adotadas e as suas respectivas metas, definidas como:

$$[\frac{meta_j - FO_{meta_j}}{meta_j}] < Q \text{ , sendo } j = 1,2,3 \text{ e } 4. \qquad (7)$$

Ou seja, o valor de Q corresponde ao mínimo valor para o máximo desvio relativo entre as estatísticas e seus respectivos valores de referências (metas).

A seguir, o PPM proposto para a combinação linear das previsões com ajuste MINIMAX, com abordagem de programação por metas:

$$Min\ \hat{p}_{VAR\ I}, \hat{p}_{VAR\ II}, \hat{p}_{VAR\ III}, \hat{p}_{VAR\ IV,}\ Q \qquad \{Q\}$$

$$s.a$$

$$\begin{cases} \omega_{MAPE} \dfrac{MAPE - Meta_{MAPE}}{Meta_{MAPE}} \leq Q \\ \omega_{MAE} \dfrac{MAE - Meta_{MAE}}{Meta_{MAE}} \leq Q \\ \omega_{MSE} \dfrac{MSE - Meta_{MSE}}{Meta_{MSE}} \leq Q \end{cases}$$

$$\begin{cases} \hat{y}_{CL,t} = [VAR\ I_t \times \hat{p}_{VAR\ I}] + [VAR\ II_t \times \hat{p}_{VAR\ II}] + [VAR\ III_t \times \hat{p}_{VAR\ III}] + [VAR\ IV_t \times \hat{p}_{VAR\ IV}] \\ \hat{p}_{VAR\ I} + \hat{p}_{VAR\ II} + \hat{p}_{VAR\ III} + \hat{p}_{VAR\ IV} = 1 \end{cases}$$

$$\begin{cases} MAPE = \dfrac{1}{T}\displaystyle\sum_{T=1}^{T} \dfrac{|\hat{y}_{CL,t} - y_t|}{y_t} \\ MAE = \dfrac{1}{T}\displaystyle\sum_{T=1}^{T} |\hat{y}_{CL,t} - y_t| \\ MSE = \dfrac{1}{T}\displaystyle\sum_{T=1}^{T} \left(\hat{y}_{CL,t} - y_t\right)^2 \end{cases}$$

$$\begin{cases} 0 \leq \hat{p}_{VAR\ I} \leq 1 \\ 0 \leq \hat{p}_{VAR\ II} \leq 1 \\ 0 \leq \hat{p}_{VAR\ III} \leq 1 \\ 0 \leq \hat{p}_{VAR\ IV} \leq 1 \end{cases}$$

Após a geração das previsões individualmente e de maneira combinada por cada um dos modelos, utilizaremos os indicadores de performance de modelos sugeridos por Hollauer (2006).

Segundo o autor, diversos indicadores têm sido desenvolvidos para avaliar e comparar a performance de modelos. Estas ferramentas estatísticas são capazes de gerar informação isenta sobre as vantagens de cada modelo de maneira que possam ser comparados sem viés de seleção ou discricionariedade. Alguns indicadores são voltados a investigar precisão, outros a adequação relativa e, finalmente, outros

tentam capturar a capacidade de acerto de tendência dos modelos em questão; para uma revisão, consultem-se Diebold e Lopez (1996).

Avaliação de Acurácia (*Evaluating forecasting accuracy*): Os critérios usuais de avaliação incluem o erro quadrático médio (MSE) ou a raiz quadrada do erro quadrático médio (RMSE), erro médio absoluto (MAE) e erro médio percentual absoluto (MAPE).

O RMSE é dependente da escala e, em geral, é utilizado para comparação de preditores:

$$RMSE = \sqrt{\frac{1}{T}\sum_{T=1}^{T}(\hat{y}_t - y_t)^2}$$

n é o número de previsões avaliadas. As comparações são feitas entre previsões *i*-passos à frente, para o mesmo *i* e modelos distintos, então esses índices, rigorosamente, são indexados em *i*.

O MAE tem propriedades semelhantes e define-se como:

$$MAE = \frac{1}{T}\sum_{T=1}^{T}|\hat{y}_t - y_t|$$

O MAPE tenta capturar a importância do erro relativo, consequentemente, está isento de problemas de escala e define-se como:

$$MAPE = \frac{1}{T}\sum_{T=1}^{T}\frac{|\hat{y}_t - y_t|}{y_t}$$

4 DADOS

Neste capítulo são apresentados os dados e séries utilizadas assim como as variáveis de análise. Além disso, apresentamos as fontes de informação das séries temporais, sendo expostas as variáveis escolhidas como explicativas, além da explicada. Em complemento, descrevemos as fontes de dados, o tratamento realizado sobre as séries temporais, os *softwares* utilizados, as estatísticas descritivas e embasamentos na literatura para tais escolhas.

As variáveis utilizadas para a modelagem são de extrema importância, pois se faz necessário encontrar as melhores *proxies* possíveis para alimentar o modelo no sentido de obter resultados que sejam mais próximos da realidade e com alto poder explicativo.

O período analisado do presente trabalho, compreende o mês de janeiro de 2002 a dezembro de 2017.A escolha do período foi devido à disponibilidade de informações relativas às variáveis utilizadas priorizando a completude de informações de maneira mais atualizada. As variáveis foram transformadas em logaritmo natural e incluídas nos modelos em primeira diferença. A variável M1 foi ajustada sazonalmente pelo Banco Central do Brasil através do X-13 *Arima Seats*, porém as demais variáveis não foram ajustadas sazonalmente.

O *software* utilizado para a geração de testes, de gráfico das variáveis, modelos VAR e das previsões individuais foi o *Eviews* versão 10. Além deste, seguindo a aplicação prática adotada por Ragsdale (2010), o *Software Microsoft Excel* foi utilizado para a aplicação do método de Programação por Metas. A partir da ferramenta *Solver* foi possível calcular cada resultado relativo as metas, estatísticas MSE, MAE e MAPE e as previsões combinadas após o procedimento de otimização multiobjetivo.

O quadro 4sumariza as variáveis utilizadas nas previsões, bem como suas fontes e o ano de coleta de tal indicador. A coluna Sigla Mnemônica corresponde ao código de letras utilizado nas tabelas e gráficos para representar aquela variável.

Quadro 4– Descrição das variáveis dependente e explicativas utilizadas nos modelos(continua)

Variável Dependente					
Variável	**Sigla Mnemônica**	**Fonte**	**Período**	**Unidade**	**Informações adicionais e Tratamento aplicado**
IPCA	DLNIPCA	IBGE	Janeiro/2002 a Dezembro/2017	Variação Percentual acumulada em 12 meses	Segundo o IBGE, o Índice Nacional de Preços ao Consumidor Amplo (IPCA) mensura o preço da cesta de bens e serviços consumidos pelas famílias com faixa de renda entre 1 e 40 salários mínimos residentes nas áreas urbanas. A periodicidade da realização da pesquisa para recolhimento de dados é mensal e, em geral, do dia 1º ao 30 do mês de referência. Neste trabalho, a variação acumulada em 12 meses foi calculada por fator de acumulação a partir da variação mensal obtida pela base de dados.
Variáveis Explicativas					
Variáveis	**Sigla Mnemônica**	**Fonte**	**Período**	**Unidade**	**Informações adicionais e Tratamento aplicado**
Taxa de câmbio nominal	DLNCAMBIO	BCB	Janeiro/2002 a Dezembro/2017	Monetária (R$/US$)	A taxa de câmbio tem a capacidade de demonstrar A Taxa de câmbio nominal foi calculada pela média do preço de compra no mercado no período mensal do Dólar americano, i.e., valor médio mensal de compra do dólar a preços de livre mercado. A taxa de câmbio permite que sejam observados o comportamento dos movimentos na taxa básica de juros sobre a taxa real de câmbio e, assim, no custo marginal das firmas e nos componentes da demanda agregada (MINELLA e SOUZA-SOBRINHO, 2011).
Taxa de Juros Real deflacionada pelo IGPM	DLNJREALIGPM	BCB	Janeiro/2002 a Dezembro/2017	Variação Percentual acumulada em 12 meses	A Taxa de Juros Real deflacionada pelo IGPM foi calculada pela variação mensal da Taxa de juros básica (SELIC) acumulada em 12 meses dividida por um Fator Acumulado da variação percentual mensal do IGPM nos mesmos 12 meses. A SELIC foi utilizada um vez que é a série que remunera as aplicações de curto prazo sendo a taxa referencial de curto prazo da economia (HOULLAUER,2006).
Taxa de Juros Real deflacionada pelo IPCA	DLNJREALIPCA	BCB	Janeiro/2002 a Dezembro/2017	Variação Percentual acumulada em 12 meses	A Taxa de Juros Real deflacionada pelo IPCA foi calculada da mesma maneira que a Taxa de Juros Real deflacionada pelo IGPM, sendo apenas modificado o índice deflator.

Quadro 4– Descrição das variáveis dependente e explicativas utilizadas nos modelos(conclusão)

Variáveis	**Sigla Mnemônica**	**Fonte**	**Período**	**Unidade**	**Informações adicionais e Tratamento aplicado**
Produção Industrial	DLNPRODIND	IBGE	Janeiro/2002 a Dezembro/2017	Número-índice baseado na variação percentual do mês anterior	O quantum da Produção industrial foi medida em Número-índice como Índice Base Fixa Mensal. Este dado permite comparar a produção do mês de referência do índice com a média mensal produzida no ano base da pesquisa (2012).
M1 (Meio de Pagamento)	DLNM1	BCB	Janeiro/2002 a Dezembro/2017	Monetária (R$)	Os meios de pagamento (M1) compreendem os passivos de liquidez imediata. São compostos pelo papel-moeda em poder do público e pelos depósitos à vista. Ela é obtida pelos saldo em final de período sendo sazonalmente ajustadas pelo BCB através pelo X-13 Arima Seats. Esta série passou por revisão histórica desde dez/2001.
Razão entre M4 e Base Monetária Ampliada	DLNM4BMA	BCB	Janeiro/2002 a Dezembro/2017	Índice	Segundo o BCB, a base monetária ampliada é calculada da seguinte forma: BMa = BMr + DC + TPF onde: BMa = Base monetária ampliada, BMr = Base monetária restrita,DC = Depósitos compulsórios em espécie, TPF = Posição de custódia com títulos do Bacen (exceto LBC-E) e do Tesouro Nacional. Enquanto isso, os meios de pagamentos ampliados (M2, M3, M4) são uma extensão do conceito mais restrito de moeda chamado de M1. Dessa forma, ao adicionar a essa medida outros haveres financeiros e títulos públicos de alta liquidez, obtêm-se os agregados monetários M2, M3 e M4, cujas definições são as seguintes: M1 é composto pelo papel-moeda em poder do público e pelos depósitos à vista compreende os passivos de liquidez imediata; M2 adiciona ao M1 os depósitos para investimentos, as cadernetas de poupança e os títulos emitidos por instituições depositárias; M3 inclui no M2 as quotas de fundos de investimentos e a posição líquida de financiamentos através de operações compromissadas lastreadas em títulos públicos federais; M4 engloba ao M3 os títulos federais, estaduais e municipais em poder do público não financeiro. Neste trabalho, a razão entre M4 e a Base Monetária ampliada foi calculada mensalmente a partir saldo do final do mês de referência de cada uma das variáveis.

Fonte: O autor, 2019.

Antes de iniciarmos a apresentação das estimações obtidas por cada modelo, cabe destacar o comportamento das séries representada nos gráficos. O Gráfico 1 representa as séries temporais das variáveis utilizadas.

Gráfico 1- Séries temporais das variáveis explicativas e explicadas em nível

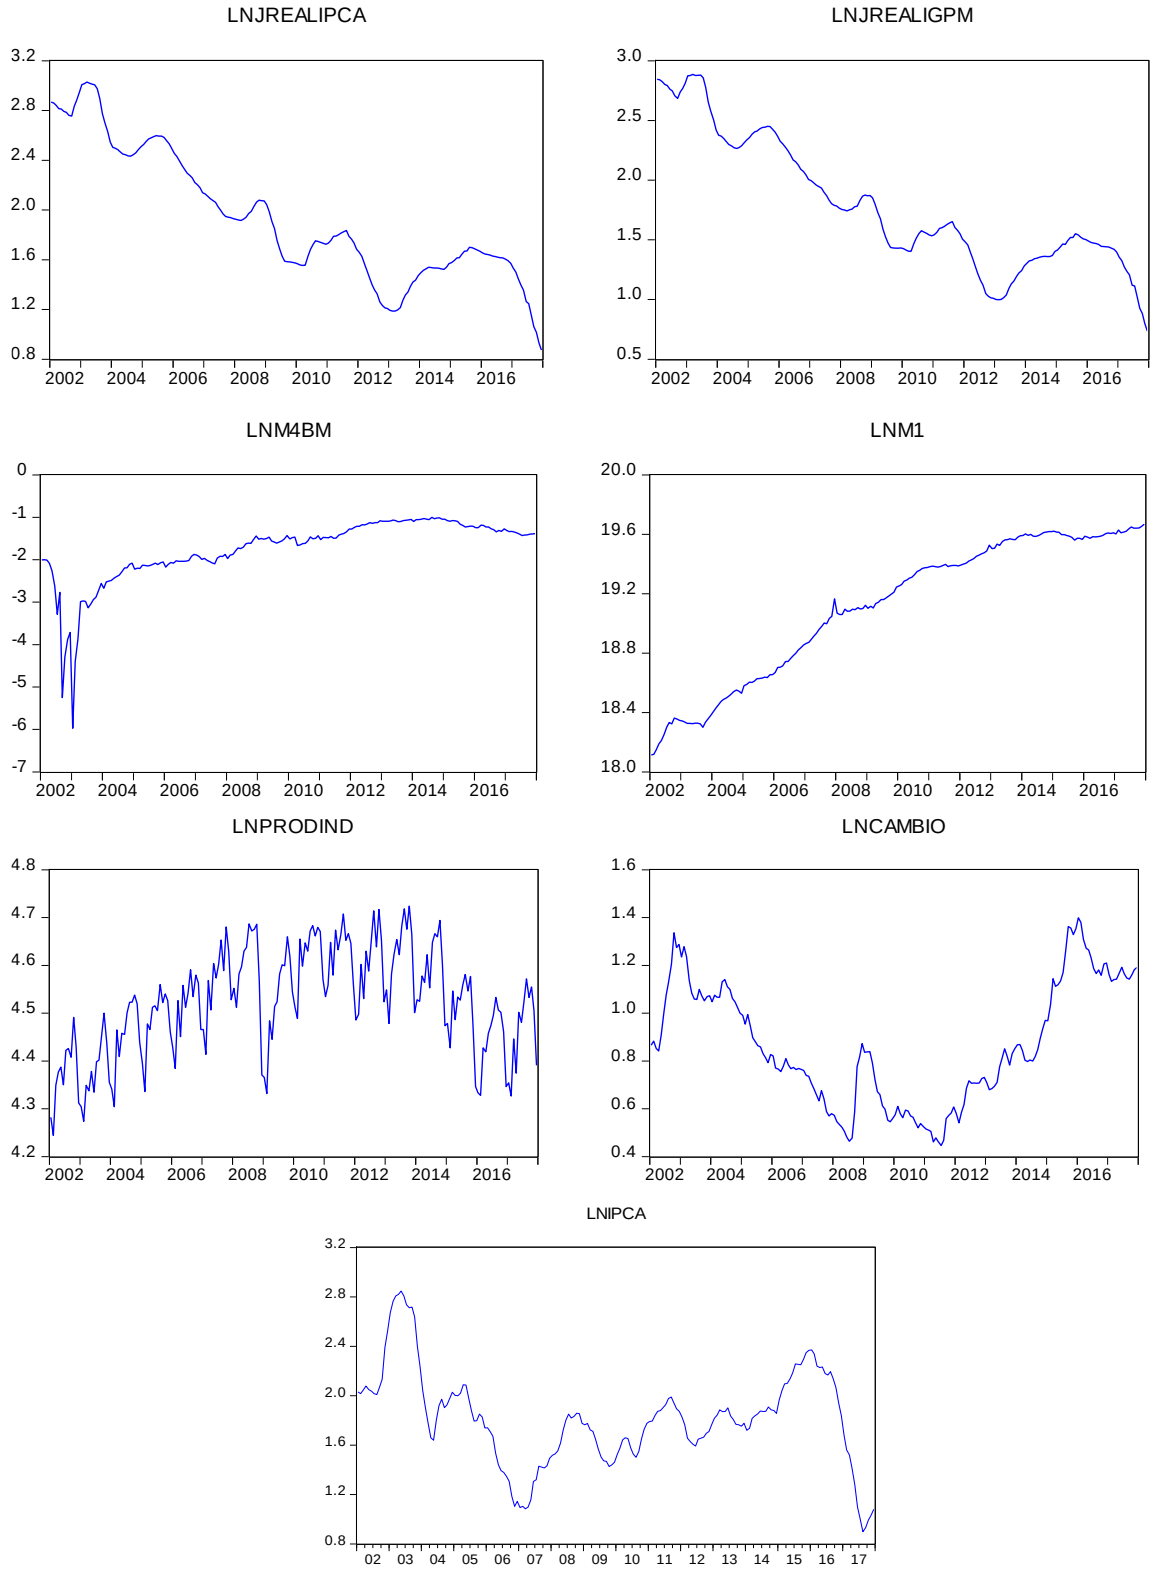

Fonte: O autor, 2019.

Pelas séries correspondentes aos juros reais deflacionados pelo IPCA e IGPM (LNJREALIPCA e LNJREALIGPM), observamos que ambas possuem o mesmo comportamento de tendência, apenas alterando os níveis percentuais de cada série.

Com relação a série da razão entre o M4 e a Base Monetária (LNM4BM), a mesma apresentou comportamento atípico entre 2002 e 2003, no entanto nos demais períodos manteve-se regular. A série LNM1 apresenta visualmente um comportamento que denota existência de raiz unitária. A série LNPRODIND, em nível, apresenta comportamento com características de sazonalidade e podemos observar comportamento atípico entre os anos de 2007 e 2008.

A série LNCAMBIO, em nível, apresentou comportamento com aspecto cíclico. Com forte elevação no ano de 2002 e decréscimo ao longo do período até 2008. Em 2009, a série apresentou forte elevação mas ocorreu queda para patamares equivalentes ao ano de 2008. Em seguida, retornou a subir até o ano de 2016 quando se comportou de forma estabilizada.

Por fim, a série LNIPCA, comportou-se com forte elevação em 2002 e quedas subsequentes até meados do ano de 2006 e início de 2007. A partir daí, permanece movimentos contínuos de ascensão e quedas em torno da média de 1,6. No entanto, isto ocorre até 2016 quando cai significativamente em relação aos períodos anteriores alcançando a mínima da série histórica em 2017.

Tabela 1 – Estatísticas descritivas das séries temporais em nível e teste Jarque-Bera

	IPCA	CAMBIO	M1	M4BM	PRODIND	JREALIPCA	JREALIGPM
Média	1.813	0.864	19.113	-1.760	4.523	1.935	1.779
Desvio Padrão	0.386	0.253	0.471	0.755	0.110	0.523	0.546
Máximo	2.847	1.399	19.668	-0.999	4.724	3.028	2.885
Mínimo	0.898	0.447	18.114	-5.973	4.244	0.874	0.734
Assimetria	0.257	0.236	-0.547	-2.260	-0.290	0.455	0.514
Curtose	3.558	1.921	1.892	10.425	2.344	2.217	2.237
Teste Jarque-Bera	4.601	11.098	19.407	604.567	6.136	11.519	13.122
Probab. (0,05)	[0.100]	[0.004]	[0.000]	[0.000]	[0.047]	[0.003]	[0.001]

Nota: As séries encontra-se em logaritmo natural e a amostra possui 192 observações (2002M01 a 2017M12).

Fonte: O autor, 2019

Na Tabela 1, apresentamos as estatísticas descritivas das séries em nível e testes Jarque-Bera (JB). No teste JB verificamos as propriedades de normalidade das séries históricas em nível. O teste JB utiliza como parâmetros os coeficientes de curtose e assimetria que na distribuição normal são 3 e 0, respectivamente. De acordo

com Bueno (2015), este teste verifica se o terceiro (assimetria) e o quarto (curtose) momentos são iguais aos da distribuição normal. Com isso, podemos verificar se a série histórica tem distribuição aproximadamente normal.

Uma vez realizados os testes para cada variável, sob a hipótese nula que a assimetria é igual a zero e a curtose é igual a 3, ao nível de significância de 5%, podemos rejeitar a hipótese nula de que a assimetria e curtose da distribuição das séries históricas coincidam com a distribuição normal, exceto para a série do IPCA.

5 RESULTADOS EMPÍRICOS E ANÁLISES

Este capítulo analisa os resultados obtidos na pesquisa empírica pela comparação e avaliação das previsões dos modelos individuais e das previsões oriundas das combinações através da metodologia proposta sendo dividido em 5 seções. A seção 5.1 apresenta os testes de raiz unitária, testes de seleção de ordens de defasagens, teste de causalidade de Granger, dentre outros testes que são usados para subsidiar as modelagens adotadas; na seção 5.2 são apresentados e analisados os resultados das estimações dos modelos VAR para amostra e da função de resposta ao impulso (FRI); na seção 5.3 apresenta as previsões obtidas em cada horizonte de previsão. Na seção 5.4, estão descritas as combinações dos modelos individuais com base na otimização Multiobjetivo MINIMAX; e por fim na seção 5.5, são avaliadas as previsões obtidas em cada horizonte de previsão sendo comparados os ganhos preditivos.

5.1 Testes de raiz unitária e gráficos das séries temporais

Para verificar a estacionaridade das variáveis realizou-se os testes Dickey Fuller Aumentado (ADF); Phillips-Perron (PP) e Kwiatkowski, Phillips, Schmidt e Shin (KPSS) para todas as séries de dados em nível e em variação mensal.

Na Tabela 2, os resultados apresentados dos testes de raiz unitária em nível ADF e PP mostram que a hipótese nula de presença de raiz unitária é rejeitada para maioria das variáveis ao nível de significância de 5%. Enquanto que no teste em nível KPSS, a hipótese nula de presença de raiz unitária não é rejeitada ao nível de significância de 5%.

Tabela 2 - Teste de raiz unitária ADF, PP e KPSS em nível

Variáveis	Estatística ADF	Valor Crítico (5%)	Probab.	Lags	Decisão
LNIPCA	-2.694	-3.434	0.240	1	RAIZ UNITÁRIA
LNCAMBIO	-1.417	-3.434	0.853	1	RAIZ UNITÁRIA
LNJREALIGPM	-2.533	-3.434	0.312	4	RAIZ UNITÁRIA
LNJREALIPCA	-2.674	-3.434	0.249	4	RAIZ UNITÁRIA
LNPRODIND	-2.093	-3.435	0.546	13	RAIZ UNITÁRIA
LNM1	-0.790	-3.434	0.964	1	RAIZ UNITÁRIA
LNM4BMA	-3.655	-3.434	0.028**	4	ESTACIONÁRIA
Variáveis	Estatística PP	Valor Crítico (5%)	Probab.	Lags	Resultado
LNIPCA	-2.122	-3.434	0.530	8	RAIZ UNITÁRIA
LNCAMBIO	-1.328	-3.434	0.878	6	RAIZ UNITÁRIA
LNJREALIGPM	-2.163	-3.434	0.507	9	RAIZ UNITÁRIA
LNJREALIPCA	-2.244	-3.434	0.462	9	RAIZ UNITÁRIA
LNPRODIND	-4.381	-3.434	0.003***	6	ESTACIONÁRIA
LNM1	-0.951	-3.434	0.947	7	RAIZ UNITÁRIA
LNM4BMA	-4.952	-3.434	0.000***	10	ESTACIONÁRIA
Variáveis	Estatística KPSS	Valor Crítico (5%)	Probab.	Lags	Resultado
LNIPCA	0.185	0.146	*	10	ESTACIONÁRIA
LNCAMBIO	0.375	0.146	-	11	RAIZ UNITÁRIA
LNJREALIGPM	0.280	0.146	-	11	RAIZ UNITÁRIA
LNJREALIPCA	0.257	0.146	-	11	RAIZ UNITÁRIA
LNPRODIND	0.409	0.146	-	9	RAIZ UNITÁRIA
LNM1	0.402	0.146	-	11	RAIZ UNITÁRIA
LNM4BMA	0.233	0.146	-	10	RAIZ UNITÁRIA

Nota: Todos o testes foram aplicados com constante e tendência. *** p < 0.01, ** p < 0.05, * p < 0.1.No teste KPSS, ao contrário dos testes ADF e PP, a hipótese nula é que a variável é estacionária.
Fonte: O autor, 2019.

No entanto, após transformação para primeiras diferenças das variáveis, conforme apresentado nas Tabela 3, a maioria das séries são estacionárias ao nível de significância de 1%. Para uma análise visual das séries em primeiras diferenças, consultar o Gráfico 2incluído no Anexo estatístico.

Tabela 3- Teste de raiz unitária ADF, PP e KPSS em primeira diferença

Variáveis	Estatística ADF	Valor Crítico (5%)	Probabilidade	Lags	Decisão
DLNIPCA	-6.126	-3.434	0.000***	0	ESTACIONÁRIA
DLNCAMBIO	-9.127	-3.434	0.000***	0	ESTACIONÁRIA
DLNJREALIGPM	-4.455	-3.434	0.002***	3	ESTACIONÁRIA
DLNJREALIPCA	-4.583	-3.434	0.001***	3	ESTACIONÁRIA
DLNPRODIND	-3.687	-3.436	0.026**	14	ESTACIONÁRIA
DLNM1	-16.074	-3.434	0.000***	0	ESTACIONÁRIA
DLNM4BMA	-16.825	-3.435	0.000***	11	ESTACIONÁRIA
Variáveis	Estatística PP	Valor Crítico (5%)	Probabilidade	Lags	Resultado
DLNIPCA	-6.130	-3.434	0.000***	1	ESTACIONÁRIA
DLNCAMBIO	-9.143	-3.434	0.000***	1	ESTACIONÁRIA
DLNJREALIGPM	-4.459	-3.434	0.002***	2	ESTACIONÁRIA
DLNJREALIPCA	-4.158	-3.434	0.006***	2	ESTACIONÁRIA
DLNPRODIND	-21.262	-3.434	0.000***	17	ESTACIONÁRIA
DLNM1	-15.899	-3.434	0.000***	7	ESTACIONÁRIA
DLNM4BMA	-19.941	-3.434	0.000***	8	ESTACIONÁRIA
Variáveis	Estatística KPSS	Valor Crítico (5%)	Probabilidade	Lags	Resultado
DLNIPCA	0.071	0.146	***	8	ESTACIONÁRIA
DLNCAMBIO	0.071	0.146	***	6	ESTACIONÁRIA
DLNJREALIGPM	0.067	0.146	***	9	ESTACIONÁRIA
DLNJREALIPCA	0.064	0.146	***	9	ESTACIONÁRIA
DLNPRODIND	0.083	0.146	***	25	ESTACIONÁRIA
DLNM1	0.037	0.146	***	7	ESTACIONÁRIA
DLNM4BMA	0.054	0.146	***	10	ESTACIONÁRIA

Nota: Todos o testes foram aplicados com constante e tendência. *** p < 0.01, ** p < 0.05, * p < 0.1. No teste KPSS, ao contrário dos testes ADF e PP, a hipótese nula é que a variável é estacionária.
Fonte: O autor, 2019.

Conforme apresentado no capítulo 3, Engle e Granger (1987) apontaram que no caso das séries temporais macroeconômicas serem não estacionárias uma combinação linear de duas ou mais séries deste tipo pode ser estacionária. Neste caso, as séries temporais não estacionárias são chamadas de cointegradas.

Na presença de cointegração, os métodos de correção de erro de vetor (VEC) ou de regressão não estacionária podem ser usados para estimar a equação de cointegração. A combinação linear estacionária pode ser interpretada como uma relação de equilíbrio de longo prazo entre as variáveis. A inclusão de tais relações de longo prazo tem sido proveitosa no trabalho de previsão, como sugerem diversos estudos (CLEMENTS; HENDRY, 1995; ENGLE; YOO, 1987; LIN; TSAY, 1996). Com base nos testes de cointegração (teste traço e autovalor), verificou-se que as variáveis no período amostral analisado não cointegram, portanto isto limita nossa análise ao curto prazo conforme era de interesse inicial. Para uma análise detalhada sobre os resultados, os testes de cointegração encontram-se na Tabela 4 no Anexo estatístico.

Para verificar a estabilidade das modelagens VAR realizamos o teste do *Graph Root*. Pelos gráficos é possível identificar se todas as raízes dos polinômios estão dentro do círculo unitário, ou seja, se as séries são conjuntamente estacionárias na especificação dos 4 modelos VAR estimados considerando cada um com 1, 2 ou 3 defasagens (*lags*). Pelo Gráfico 3 apresentamos cada uma das modelagens de acordo com as variáveis utilizadas e seus respectivos *lags*.

Gráfico 3- Raízes inversas do polinômio característico (continua)

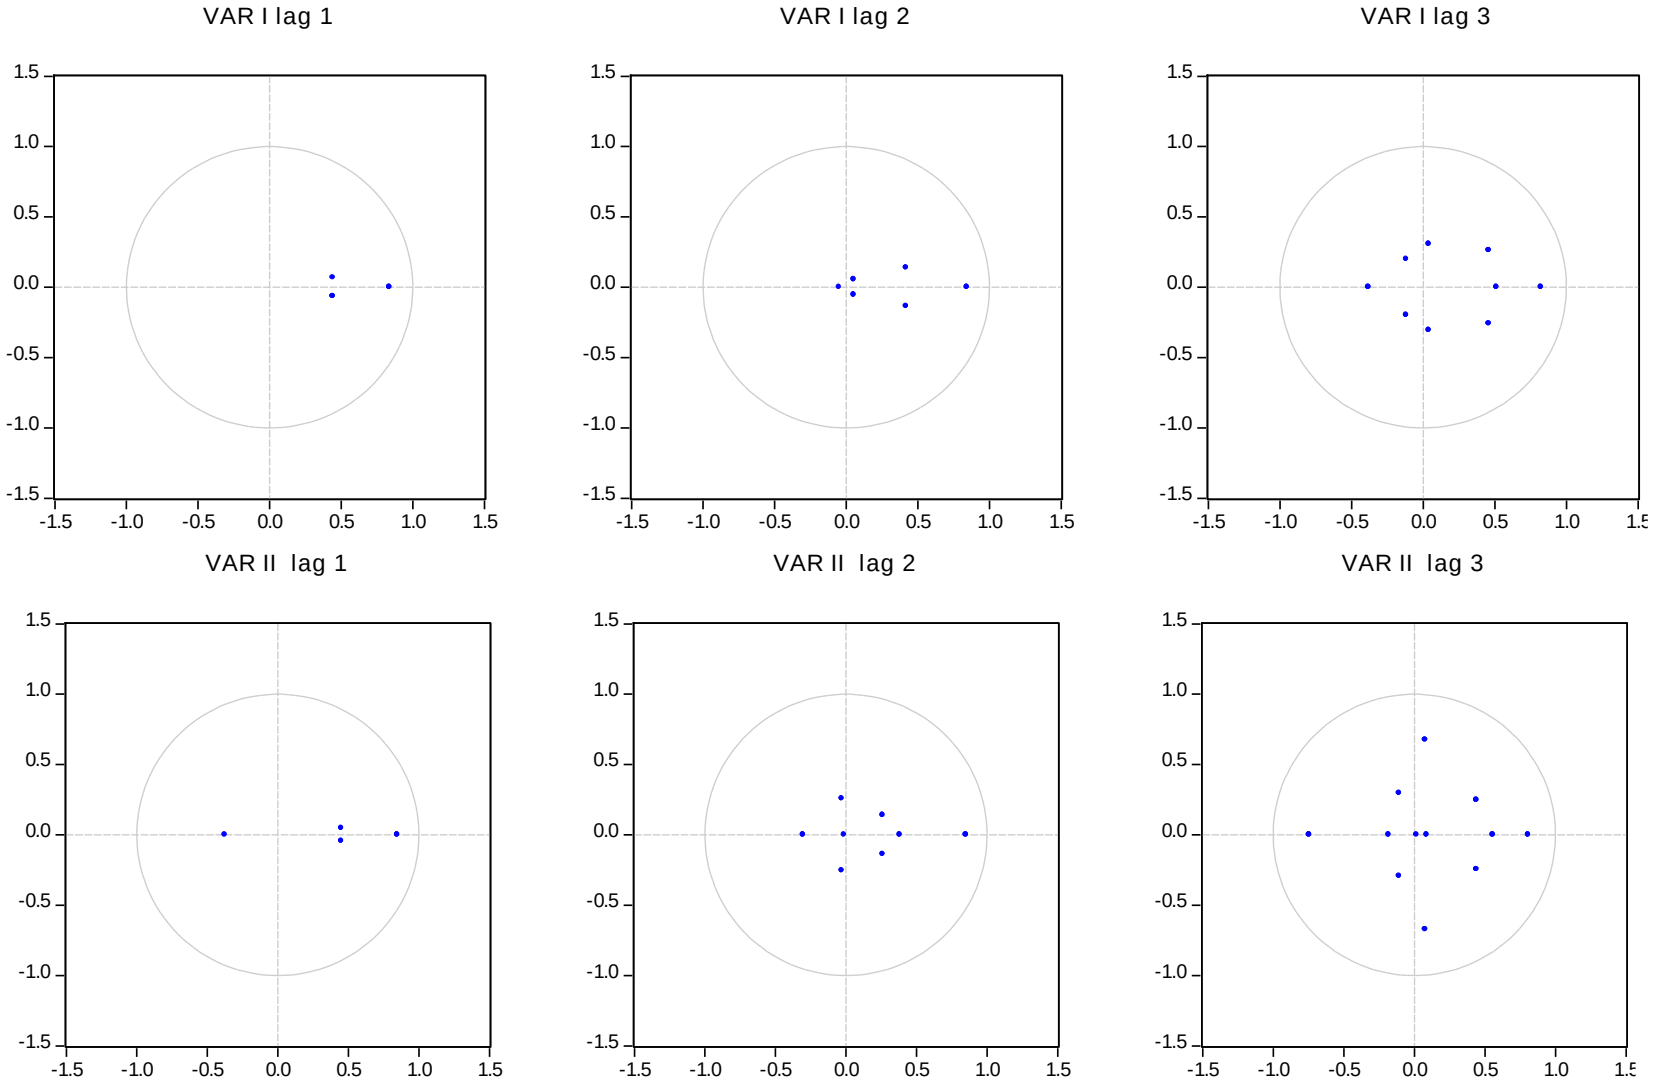

Gráfico 3- Raízes inversas do polinômio característico (conclusão)

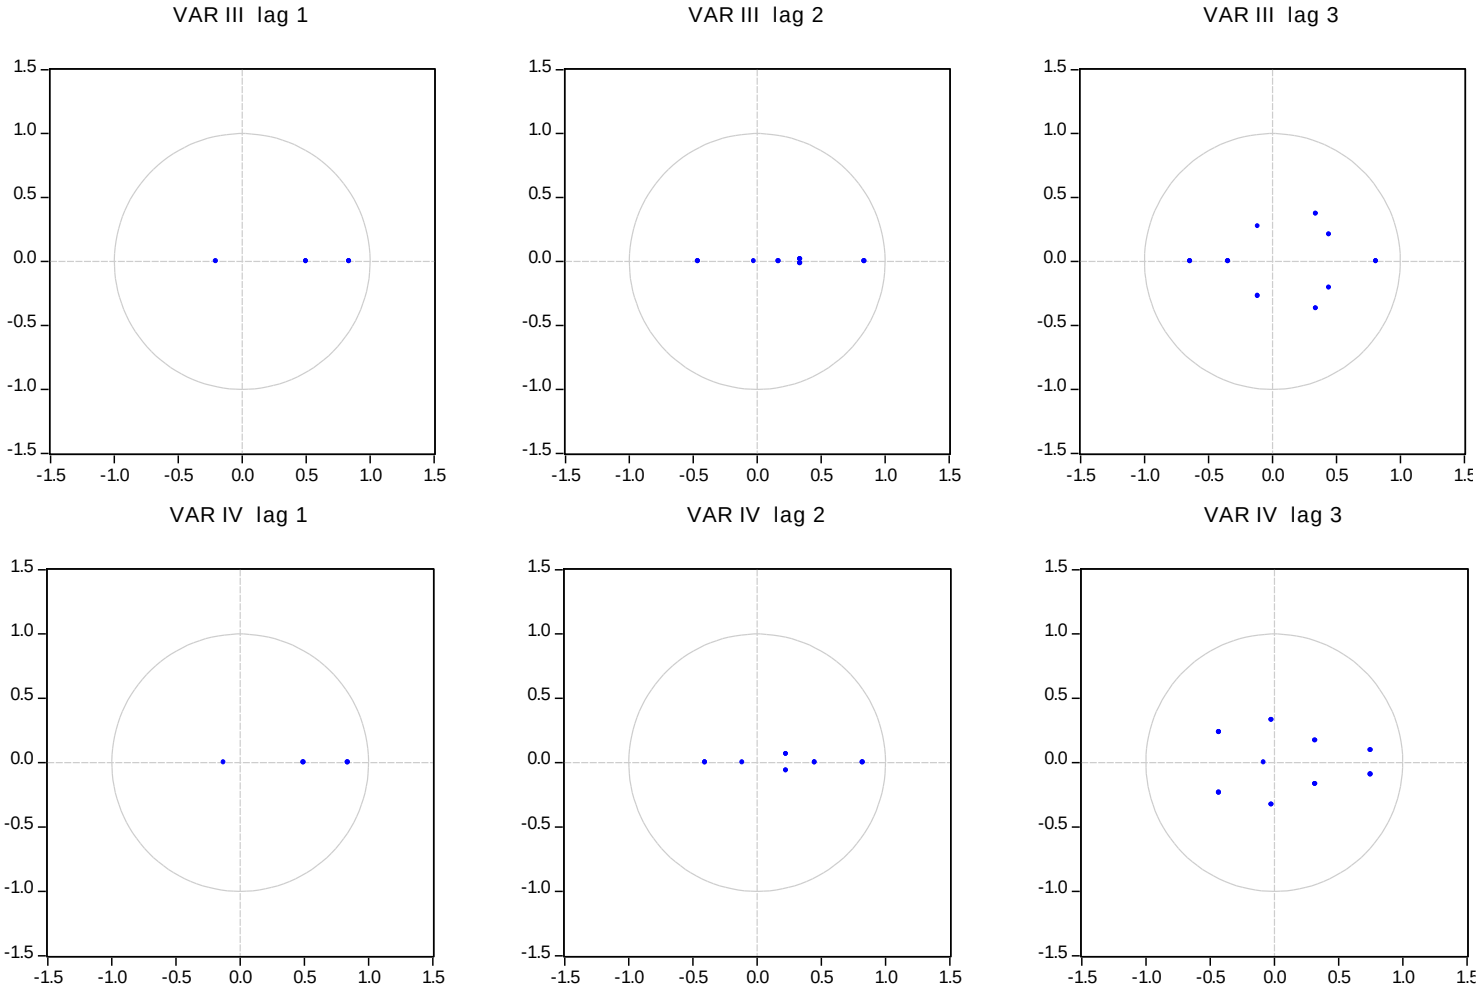

Fonte: O autor, 2019.

Quanto a seleção de ordem de defasagens (*Lag Order Selection Criteria*), utilizamos a ordem máxima ($p_{máx}$) do teste como $p_{máx} = 12$. Os testes de seleção descritos foram: LR (LR test), FPE (*Final prediction error*), AIC (*Akaike information criterion*), SC (*Schwarz information criterion*), e HQ (*Hannan-Quinn information criterion*) onde cada teste foi realizado ao nível de 5%. No entanto, apesar dos resultados destes testes apontarem em maioria para modelagens onde a ordem do teste seja I(1) decidiu-se por estimar modelos com ordem I(1), I(2) e I(3),ou seja, além dos critérios de parcimônia e bom senso necessário a qualquer pesquisador na escolha dos *lags,* a fim de evitar a sobreparametrização, esperamos que o modelo seja bom previsor da inflação. Isto porque um modelo pode ser bem ajustado a série temporal mas suas previsões podem ser pouco acuradas quando analisadas fora-da-amostra, isto que queremos evitar. A Tabela 5 com os testes de *Lag Order* encontram-se no Anexo estatístico.

No intuito de conhecer se uma variável do modelo é capaz de prever a outra e em que condições utilizou-se o teste de causalidade de Granger. Desta forma, pela especificação dos 4 modelos VAR estimados considerando cada um com *lag* 1, 2 e 3 obtivemos os resultados conforme descritos na Tabela 6.

Pelos resultados obtidos, em termos específicos, observamos que a variável DLNIPCA é dita ser causada por Granger pelas variáveis DLNJRIGPM e DLNJRIPCA. Logo, podemos dizer que DLNJRIGPM e DLNJRIPCA ajudam na previsão de DLNIPCA. No entanto, também verificou-se que as variáveis DLNJRIGPM e DLNJRIPCA são causadas por Granger pela variável DLNIPCA. Com isso, podemos dizer que as variáveis possuem uma relação recíproca de causalidade de Granger.

Com relação as demais, observou-se que a variável DLNM1 é dita ser causada no sentido de Granger pela variável DLNIPCA; a variável DLNJRIGPM é causada no sentido de Granger pela DLNPRODIND e a variável DLCAMBIO é causada no sentido de Granger pela DLNM4BM.

Em termos gerais, com base em todas as modelagens VAR foi possível constatar a existência de relação de causalidade-Granger entre as variáveis. Ademais, não houve qualquer resultado que se confrontasse nas diferentes modelagens, ou seja, a causalidade-Granger não invertia o sentido nos diferentes arranjos VAR.

Tabela 6- Testes de causalidade de Granger (continua)

		Lag 1	Lag 1	Lag 2	Lag 2	Lag 3	Lag 3
Modelo	**Hipótese Nula (H_o)**	**Estatística F**	**Prob.**	**Estatística F**	**Prob.**	**Estatística F**	**Prob.**
VAR I	DLNJRIGPM não Granger-causa DLNIPCA	4.923	0.028**	2.764	0.0657*	2.604	0.053*
	DLNIPCA não Granger-causa DLNJRIGPM	6.919	0.009**	3.349	0.037**	2.121	0.099*
	DLNCAMBIO não Granger-causa DLNIPCA	3.716	0.055*	1.825	0.164	2.006	0.115
	DLNIPCA não Granger-causa DLNCAMBIO	0.032	0.859	0.046	0.955	0.215	0.886
	DLNCAMBIO não Granger-causa DLNJRIGPM	0.266	0.606	0.487	0.616	0.849	0.469
	DLNJRIGPM não Granger-causa DLNCAMBIO	1.386	0.241	0.764	0.467	0.516	0.672
VAR II	DLNJRIPCA não Granger-causa DLNIPCA	7.412	0.007***	4.137	0.018**	3.669	0.013**
	DLNIPCA não Granger-causa DLNJRIPCA	6.205	0.014**	2.382	0.095*	1.590	0.194
	DLNM4BM não Granger-causa DLNIPCA	0.617	0.433	4.552	0.012**	2.932	0.035**
	DLNIPCA não Granger-causa DLNM4BM	0.012	0.911	0.378	0.686	1.649	0.180
	DLNCAMBIO não Granger-causa DLNIPCA	3.716	0.055*	1.825	0.164	2.006	0.115
	DLNIPCA não Granger-causa DLNCAMBIO	0.032	0.859	0.046	0.955	0.215	0.886
	DLNM4BM não Granger-causa DLNJRIPCA	1.733	0.190	1.192	0.306	1.058	0.368
	DLNJRIPCA não Granger-causa DLNM4BM	0.150	0.699	0.082	0.921	0.125	0.945
	DLNCAMBIO não Granger-causa DLNJRIPCA	0.010	0.919	0.127	0.881	0.279	0.841
	DLNJRIPCA não Granger-causa DLNCAMBIO	0.652	0.421	0.373	0.690	0.247	0.863
	DLNCAMBIO não Granger-causa DLNM4BM	1.661	0.199	2.178	0.116	5.252	0.002***
	DLNM4BM não Granger-causa DLNCAMBIO	24.223	0.000***	12.306	0.000***	8.453	0.000***
VAR III	DLNJRIGPM não Granger-causa DLNIPCA	4.923	0.028**	2.764	0.066*	2.604	0.053*
	DLNIPCA não Granger-causa DLNJRIGPM	6.919	0.009***	3.349	0.0373**	2.121	0.099*
	DLNPRODIND não Granger-causa DLNIPCA	0.063	0.802	0.041	0.960	0.142	0.935
	DLNIPCA não Granger-causa DLNPRODIND	0.540	0.463	0.329	0.720	0.298	0.827
	DLNPRODIND não Granger-causa DLNJRIGPM	3.890	0.050**	3.373	0.036**	3.026	0.031**
	DLNJRIGPM não Granger-causa DLNPRODIND	0.303	0.583	0.503	0.606	1.267	0.287

Tabela 6- Testes de causalidade de Granger (conclusão)

		Lag 1	Lag 1	Lag 2	Lag 2	Lag 3	Lag 3
Modelo	**Hipótese Nula (H_o)**	**Estatística F**	**Prob.**	**Estatística F**	**Prob.**	**Estatística F**	**Prob.**
VAR IV	DLNJRIGPM não Granger-causa DLNIPCA	4.923	0.028**	2.764	0.066*	2.604	0.053*
	DLNIPCA não Granger-causa DLNJRIGPM	6.919	0.009**	3.349	0.037**	2.121	0.099*
	DLNM1 não Granger-causa DLNIPCA	0.279	0.598	0.290	0.748	0.938	0.423
	DLNIPCA não Granger-causa DLNM1	5.725	0.0177**	2.702	0.070*	2.338	0.075*
	DLNM1 não Granger-causa DLNJRIGPM	0.514	0.474	0.272	0.763	1.198	0.312
	DLNJRIGPM não Granger-causa DLNM1	7.677	0.000***	4.993	0.000***	4.012	0.000***

Nota: *** p < 0.01, ** p < 0.05, * p < 0.1. Exemplo: ** denota rejeição da hipótese nula no nível 0,05. Os modelos com *lag* 1foram testados com 190 observações, *lag* 2 com 189 observações e *lag* 3 com 188 observações.

Fonte: O autor, 2019.

5.2 Resultados das estimações e funções de resposta ao impulso

Com base nos testes apresentados na seção anterior, apresentamos no Quadro 5 um sumário dos modelos estimados com as informações das variáveis endógenas, período amostral e defasagens utilizadas.

Quadro 5 – Resumo dos VAR utilizados para estimação e previsão

Modelos	**Defasagens**	**Período Amostral**	**Horizontes Preditivos**
VAR I	1-1	2002M01 - 2016M12	12 meses
VAR II	1-2	2002M01 - 2017M06	6 meses
VAR III	1-3	2002M01 - 2017M09	3 meses
VAR IV			

Fonte: O autor, 2019.

Os modelos VAR I a VAR IV utilizam as variáveis endógenas, tal como proposto nos relatórios do BCB (2003). No entanto, temos como objetivo prever o IPCA acumulado durante 12 meses, logo não utilizamos como variáveis a inflação dos preços administrados e dos preços livres. Como visto a partir dos testes realizados na seção anterior, as variáveis endógenas selecionadas possuem as características necessárias para gerar boas estimativas e previsões.

Em face dos testes de seleção de ordem de defasagens indicarem em maioria para modelagens onde a ordem do teste seja I(1), a seguir, no Quadro 6, apresentamos um extrato das estimações dos 4 modelos VAR com 1 defasagem no período amostral de 2002M03 até 2016M12. Além destas, todas as estimativas geradas com base nas modelagens VAR e suas defasagens nas amostras utilizadas para as previsões no horizonte de 12, 6 e 3 meses podem ser analisadas nos Quadros 7, 8 e 9 contidos no Anexo estatístico.

Através da análise de significância dos coeficientes dos modelos VAR nas 3 defasagens, observa-se que no período amostral utilizado para calcular as 3 previsões 12 meses adiante a maioria dos coeficientes descrevem o comportamento da variável DLNIPCA. Porém, as variáveis DLNPRODIND e DLNM1 não foram estatisticamente significativas. Portanto, isto nos indica pelas estimações dos modelos que a série relativa a M1 e PRODIND não reage a desequilíbrios. Na ocorrência de um choque não serão estas variáveis as responsáveis em trazer o modelo de volta ao estado

estacionário, porém as demais. Para o horizonte de 6 meses, os coeficientes que descrevem a variável DLNIPCA apresentaram o mesmo comportamento que em 12 meses. Contudo, para o horizonte de 3 meses a variável DLCAMBIO também não apresentou coeficientes estatisticamente significativos.

Pela análise da função de resposta ao impulso (FRI) podemos conhecer a trajetória do efeito de um choque de uma só vez para uma das inovações sobre valores atuais e futuros das variáveis endógenas. Em termos gerais, um incremento unitário (impulso) na inovação da *j*-ésima variável, no tempo *t*, gera uma resposta sobre a *i*-ésima variável, mantendo as demais variáveis constante. Uma vez que neste trabalho focamos a análise em prever a inflação brasileira, as FRI apresentadas pelos Gráfico 4, correspondem às respostas da variável DLNIPCA a choques das variáveis endógenas de cada modelagem, com intervalos de confiança de 95%, referente aos modelos VAR com apenas 1 defasagem. Os Gráficos 5 e 6 apresentam as FRI referentes aos modelos VAR com 2 e 3 defasagens, respectivamente, que estão incluídos no Anexo estatístico.

Os resultados referentes às FRI encontrados neste trabalho estão alinhados com a teoria econômica e as evidências encontradas por Alencar (2006), Chan (2009) e Abreu (2015). Com base nas FRI, observa-se que no caso de choque positivo na variável DLNIPCA teremos aumento de inflação (inércia inflacionária). Além disso, a inflação aumentará em reação a choques positivos em taxa de câmbio (DLNCAMBIO) e na taxa de juros reais (DLNJRIGPM e DLNJRIPCA).

No caso das variáveis relativas à moeda (DLNM1 e DLNM4BM) a inflação aumenta em reação a choques positivos em DLNM1. No entanto, a inflação aumenta em reação a choques positivos em DLNM4BM nos períodos iniciais, mas no 3 passo à frente tem efeito contrário sob a inflação. Isto pode estar associado ao fato desta variável representar o comportamento dos títulos públicos de prazo mais longo. Com relação a DLNPRODIND, ao contrário do que foi encontrado por Abreu (2015) mas da mesma maneira que Chan (2009), verificamos que choques positivos na produção industrial aumentam a inflação nos períodos iniciais, mas logo retorna para o nível estacionário.

Quadro 6– Extrato da estimação dos 4 modelos VAR com 1 defasagem no período amostral: 2002M03 até 2016M12

VAR I – LAG 1-1

	DLNIPCA
DLNIPCA(-1)	0.585676
	(0.06034)
	[9.70631]***
DLNJRIGPM(-1)	0.368794
	(0.12979)
	[2.84140]***
DLNCAMBIO(-1)	0.173007
	(0.09268)
	[1.86670]*
C	0.001906
	(0.00384)
	[0.49656]
R-squared	0.444175
Adj. R-squared	0.434592
Sum sq. resids	0.421375
S.E. equation	0.049211
F-statistic	46.34947
Log likelihood	285.5244
Akaike AIC	-3.163196
Schwarz SC	-3.091695
Mean dependent	-0.001000
S.D. dependent	0.065445

VAR II – LAG 1-1

	DLNIPCA
DLNIPCA(-1)	0.571849
	(0.06098)
	[9.37792]***
DLNM4BM(-1)	0.010570
	(0.01179)
	[0.89630]
DLNJRIPCA(-1)	0.415741
	(0.12835)
	[3.23924]***
DLNCAMBIO(-1)	0.159060
	(0.09265)
	[1.71682]*
C	0.001914
	(0.00379)
	[0.50526]
R-squared	0.453934
Adj. R-squared	0.441308
Sum sq. resids	0.413977
S.E. equation	0.048918
F-statistic	35.95287
Log likelihood	287.1008
Akaike AIC	-3.169672
Schwarz SC	-3.080296
Mean dependent	-0.001000
S.D. dependent	0.065445

VAR III – LAG 1-1

	DLNIPCA
DLNIPCA(-1)	0.580229
	(0.06080)
	[9.54364]***
DLNPRODIND(-1)	0.035466
	(0.05819)
	[0.60948]
DLNJRIGPM(-1)	0.395519
	(0.13044)
	[3.03230]***
C	0.002412
	(0.00386)
	[0.62461]
R-squared	0.434252
Adj. R-squared	0.424498
Sum sq. resids	0.428898
S.E. equation	0.049648
F-statistic	44.51917
Log likelihood	283.9495
Akaike AIC	-3.145500
Schwarz SC	-3.073999
Mean dependent	-0.001000
S.D. dependent	0.065445

VAR IV – LAG 1-1

	DLNIPCA
DLNIPCA(-1)	0.583064
	(0.06108)
	[9.54592]***
DLNJRIGPM(-1)	0.397853
	(0.13073)
	[3.04332]***
DLNM1(-1)	0.118558
	(0.21254)
	[0.55782]
C	0.001475
	(0.00422)
	[0.34949]
R-squared	0.434056
Adj. R-squared	0.424299
Sum sq. resids	0.429046
S.E. equation	0.049657
F-statistic	44.48371
Log likelihood	283.9187
Akaike AIC	-3.145154
Schwarz SC	-3.073653
Mean dependent	-0.001000
S.D. dependent	0.065445

Nota: Foram utilizadas 178 observações depois dos ajustamentos. Os desvios-padrão encontram-se em ( ) e t-estatístico em [ ].
Fonte: O autor, 2019.

Gráfico 4- Funções de resposta ao impulso (FRI) dos modelos VAR com 1 defasagem

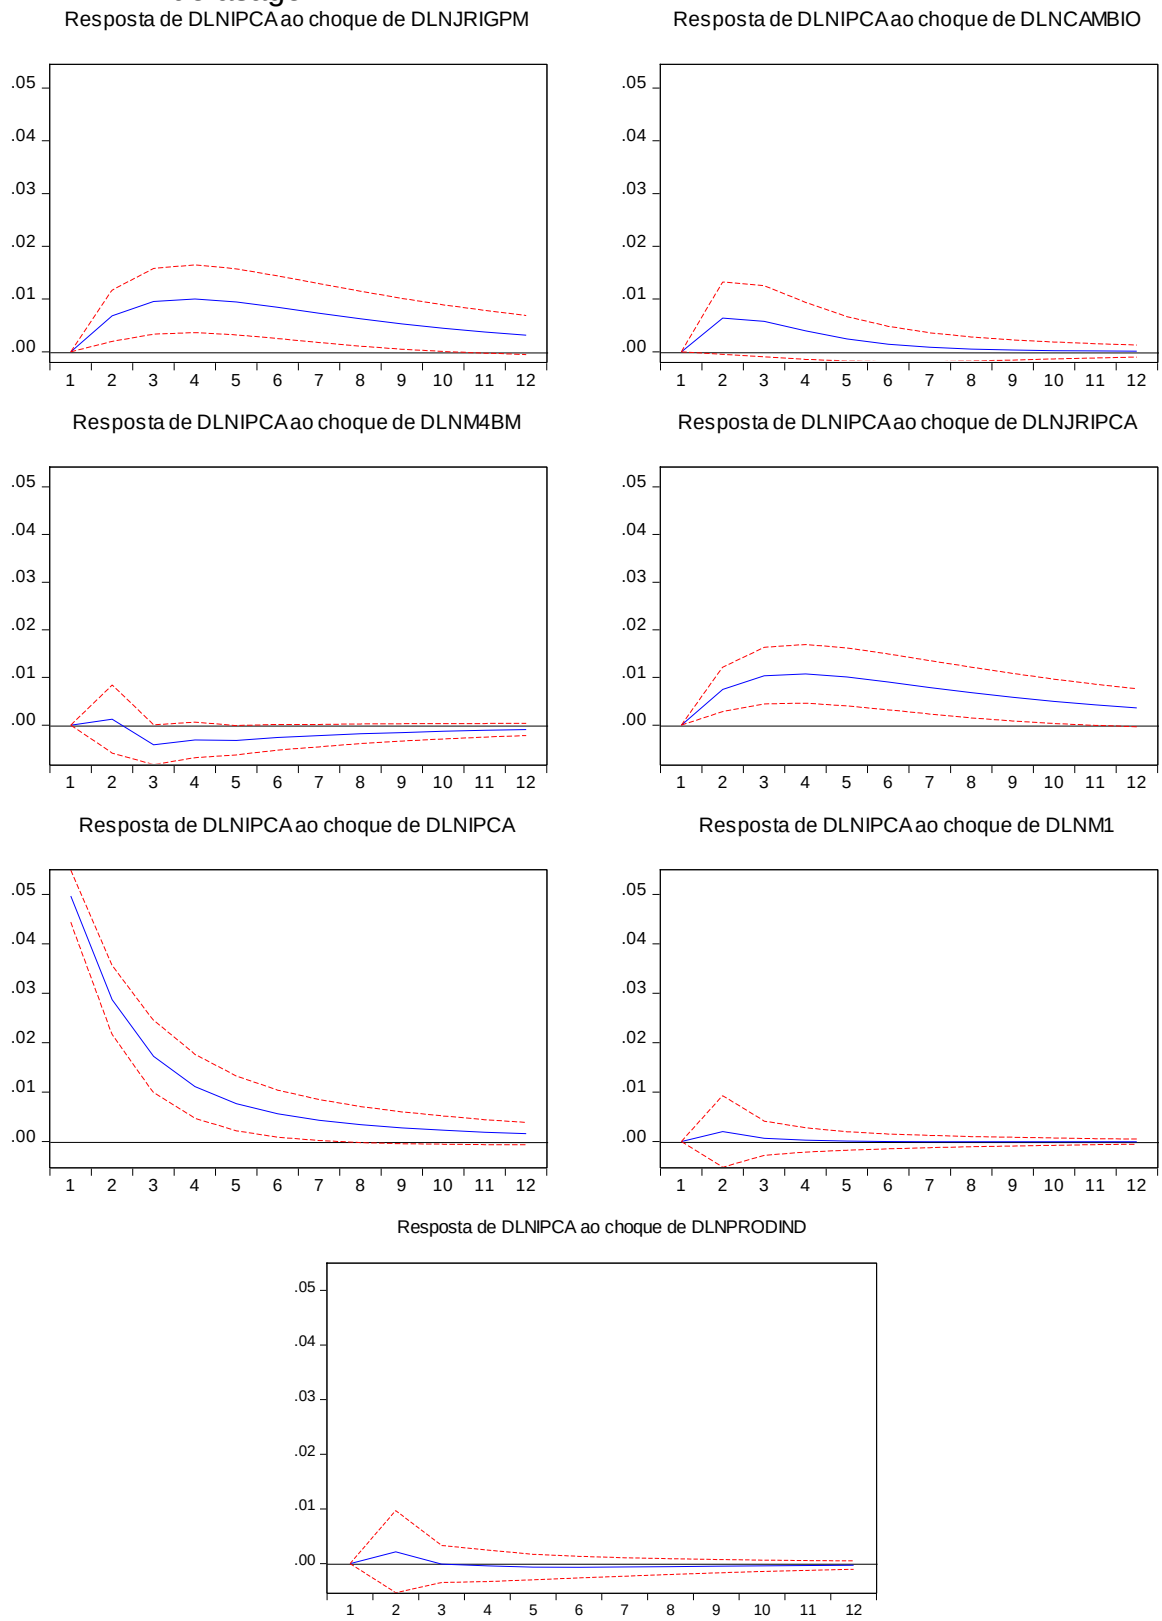

Fonte: O autor, 2019.

5.3 Previsões individuais

Após a especificação dos modelos, as estimativas são realizadas dentro da amostra podendo variar o espaço amostral segundo o número de *lags* atribuído em cada modelagem ou horizonte preditivo. Como apresentado no Quadro 3, para o horizonte de previsão de 12 meses, as estimações utilizam o espaço amostral entre 2002M01 e 2016M12; no horizonte de previsão de 6 meses, as estimações utilizam o espaço amostral de 2002M01 até 2017M06; e por fim, no horizonte de previsão de 3 meses, as estimações utilizam o espaço amostral de 2002M01 até 2017M09.

As previsões para os 3 horizontes preditivos foram realizadas seguindo o método estático e dinâmico. Pelo método estático, as previsões (*t+1*) são calculadas com base nos dados (*actuals*) que ocorreram no período *t*, ou seja, utilizamos os dados do período anterior para calcular a previsão um passo à frente (*t+1*). Com isso, este processo se repete a cada passo à frente. Ao utilizarmos o método estático são necessários os valores que efetivamente ocorreram no período *t*.

Pelo método dinâmico, as previsões são calculadas com base em outras previsões tantos passos à frente sejam necessários prever. Isto quer dizer que as previsões (*t+1*) são calculadas com base nos dados que ocorreram no período *t*. No entanto, as previsões (*t+2*) são calculadas com base nas previsões calculadas para o período *t+1*. Portanto, em *t+1* a previsão apresentará o mesmo valor em ambos os métodos somente diferindo a partir do segundo período e nos períodos subsequente do horizonte de previsão.

Em tese, em horizontes com muitos passos adiante o método dinâmico apresenta uma predição menos acurada em relação ao método estático visto que realiza “previsão em cima de previsões” e não “previsão em cima de valores reais”. Isto pode ser observado ao compararmos os erros quadráticos médios na Tabela 7 com os da Tabela 8. Na Tabela 7, temos uma média calculada de 0,0046 para todos os modelos, enquanto que na Tabela 8 temos uma média de 0,0075. Com isso, observamos que a capacidade preditiva se deteriora ao longo dos períodos mais para o método dinâmico do que no estático.

A Tabela 7 apresenta a previsão mensal de 12 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados

individualmente com base no método estático, ou seja, a previsão mês a mês da primeira diferença do logaritmo do IPCA acumulado para o horizonte de 12 meses. A última linha da tabela (MSE) representa a estatística do Erro Quadrático Médio de cada modelo para o horizonte de 12 meses.

O Erro Quadrático Médio (MSE) de cada modelo é calculado pela média do somatório do quadrático das diferenças mensais entre o valor da coluna IPCA12M e o valor da coluna com as previsões de cada modelo. Para uma análise mais detalhada do cálculo do MSE é possível verificar a fórmula descrita no capítulo 3. Na Tabela7, podemos observar que os 3 modelos que apresentaram as menores estatísticas MSE, em ordem crescente, foram: VAR II 3 *lags*, VAR IV 3 *lags* e VAR I 3 *lags*. A opção pelo modelo com apenas 1 defasagem, como indicado pelos testes de seleção de ordem de defasagem AIC, SC e HQ, apresentados na seção 5.1, nos levaria a projetar apenas com base em modelos com maiores MSE em comparação ao que foi sugerido pelos testes. Logo, podemos dizer que através das modelagens VAR deste trabalho com apenas 1 defasagem teríamos resíduos brancos em todas variáveis endógenas, porém não seriam as modelagens capazes de gerar menores erros de previsão.

No Gráfico 7, apresentamos a trajetória das previsões para o horizonte de 12 meses porém representando apenas o retorno do IPCA acumulado por 12 meses e as séries que correspondem aos 3 modelos que possuem menor estatística MSE pelo método estático.

A Tabela8 também apresenta a previsão mensal de 12 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados individualmente pelo método dinâmico. Como foi mencionado anteriormente neste trabalho, o método dinâmico em horizontes longos de tempo deteriora suas previsões mais rapidamente que o no método estático. Isto se dá porque o método dinâmico, realiza as previsões do período *t+2* com base em previsões de *t+1*. Assim, as previsões deste método possuem uma memória que acompanha as previsões ao longo dos períodos.

Tabela 7 – Retorno IPCA acumulado: previsões individuais pelos modelos VAR com base no método estático (12 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M012017	-0.161	-0.068	-0.065	-0.070	-0.066	-0.060	-0.064	-0.072	-0.069	-0.070	-0.069	-0.068	-0.069
M022017	-0.118	-0.116	-0.117	-0.108	-0.114	-0.110	-0.101	-0.107	-0.108	-0.104	-0.110	-0.111	-0.110
M032017	-0.040	-0.082	-0.077	-0.076	-0.083	-0.073	-0.071	-0.078	-0.072	-0.074	-0.075	-0.074	-0.078
M042017	-0.113	-0.040	-0.037	-0.032	-0.043	-0.036	-0.032	-0.038	-0.033	-0.024	-0.046	-0.039	-0.036
M052017	-0.127	-0.077	-0.078	-0.079	-0.083	-0.086	-0.084	-0.080	-0.083	-0.077	-0.078	-0.086	-0.075
M062017	-0.182	-0.079	-0.077	-0.075	-0.084	-0.083	-0.083	-0.078	-0.076	-0.077	-0.083	-0.083	-0.092
M072017	-0.101	-0.132	-0.135	-0.131	-0.136	-0.135	-0.131	-0.138	-0.140	-0.136	-0.138	-0.139	-0.136
M082017	-0.099	-0.064	-0.052	-0.058	-0.067	-0.056	-0.059	-0.057	-0.048	-0.056	-0.058	-0.052	-0.060
M092017	0.033	-0.093	-0.096	-0.068	-0.096	-0.088	-0.069	-0.089	-0.089	-0.068	-0.093	-0.092	-0.072
M102017	0.062	-0.015	-0.009	-0.023	-0.019	-0.011	-0.018	-0.018	-0.012	-0.022	-0.018	-0.017	-0.023
M112017	0.037	0.026	0.028	0.034	0.022	0.017	0.022	0.022	0.022	0.032	0.021	0.018	0.019
M122017	0.050	-0.004	-0.009	-0.002	-0.007	-0.013	-0.010	-0.011	-0.016	-0.009	-0.009	-0.014	-0.012
MSE		**0.00465**	**0.00486**	**0.00440**	**0.00467**	**0.00468**	**0.00431**	**0.00471**	**0.00486**	**0.00458**	**0.00462**	**0.00475**	**0.00434**

Fonte: O autor, 2019.

Gráfico 7- Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (12 passos à frente)

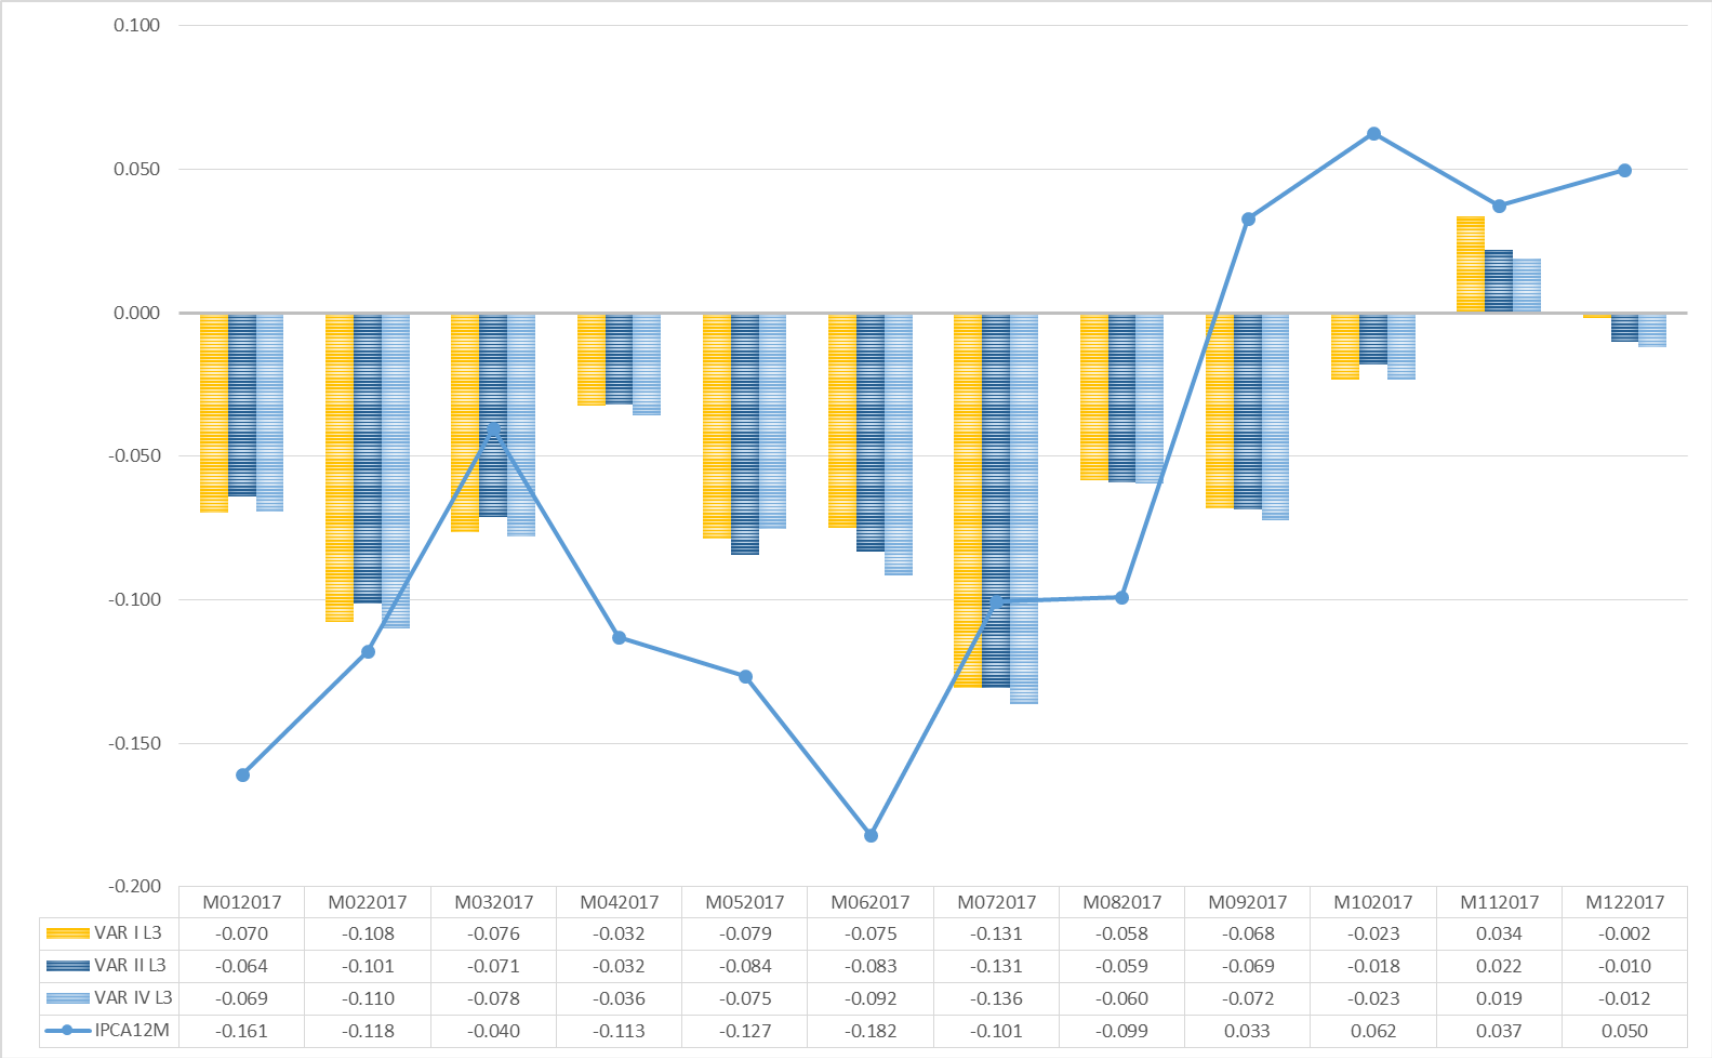

	M012017	M022017	M032017	M042017	M052017	M062017	M072017	M082017	M092017	M102017	M112017	M122017
VAR I L3	-0.070	-0.108	-0.076	-0.032	-0.079	-0.075	-0.131	-0.058	-0.068	-0.023	0.034	-0.002
VAR II L3	-0.064	-0.101	-0.071	-0.032	-0.084	-0.083	-0.131	-0.059	-0.069	-0.018	0.022	-0.010
VAR IV L3	-0.069	-0.110	-0.078	-0.036	-0.075	-0.092	-0.136	-0.060	-0.072	-0.023	0.019	-0.012
IPCA12M	-0.161	-0.118	-0.040	-0.113	-0.127	-0.182	-0.101	-0.099	0.033	0.062	0.037	0.050

Fonte: O autor, 2019.

Tabela 8– Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (12 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M012017	-0.161	-0.068	-0.065	-0.070	-0.066	-0.060	-0.064	-0.072	-0.069	-0.070	-0.069	-0.068	-0.069
M022017	-0.118	-0.047	-0.041	-0.037	-0.045	-0.038	-0.034	-0.047	-0.043	-0.039	-0.047	-0.046	-0.047
M032017	-0.040	-0.034	-0.028	-0.020	-0.033	-0.027	-0.020	-0.034	-0.032	-0.024	-0.034	-0.033	-0.032
M042017	-0.113	-0.027	-0.022	-0.012	-0.026	-0.020	-0.009	-0.026	-0.025	-0.020	-0.027	-0.025	-0.023
M052017	-0.127	-0.022	-0.018	-0.009	-0.021	-0.017	-0.007	-0.021	-0.021	-0.018	-0.021	-0.020	-0.017
M062017	-0.182	-0.018	-0.015	-0.008	-0.017	-0.014	-0.005	-0.017	-0.018	-0.016	-0.018	-0.017	-0.013
M072017	-0.101	-0.015	-0.013	-0.007	-0.015	-0.012	-0.006	-0.014	-0.015	-0.014	-0.015	-0.014	-0.010
M082017	-0.099	-0.013	-0.011	-0.007	-0.013	-0.011	-0.005	-0.012	-0.013	-0.012	-0.013	-0.012	-0.008
M092017	0.033	-0.012	-0.010	-0.006	-0.011	-0.009	-0.005	-0.011	-0.012	-0.010	-0.011	-0.011	-0.006
M102017	0.062	-0.010	-0.009	-0.006	-0.010	-0.008	-0.004	-0.009	-0.010	-0.008	-0.010	-0.009	-0.005
M112017	0.037	-0.009	-0.008	-0.005	-0.009	-0.007	-0.004	-0.008	-0.009	-0.007	-0.008	-0.008	-0.004
M122017	0.050	-0.008	-0.007	-0.004	-0.008	-0.007	-0.003	-0.007	-0.008	-0.006	-0.008	-0.007	-0.004
MSE		**0.00719**	**0.00758**	**0.00815**	**0.00730**	**0.00778**	**0.00845**	**0.00719**	**0.00728**	**0.00748**	**0.00720**	**0.00729**	**0.00747**

Fonte: O autor, 2019.

Gráfico 8- Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método dinâmico (12 passos à frente)

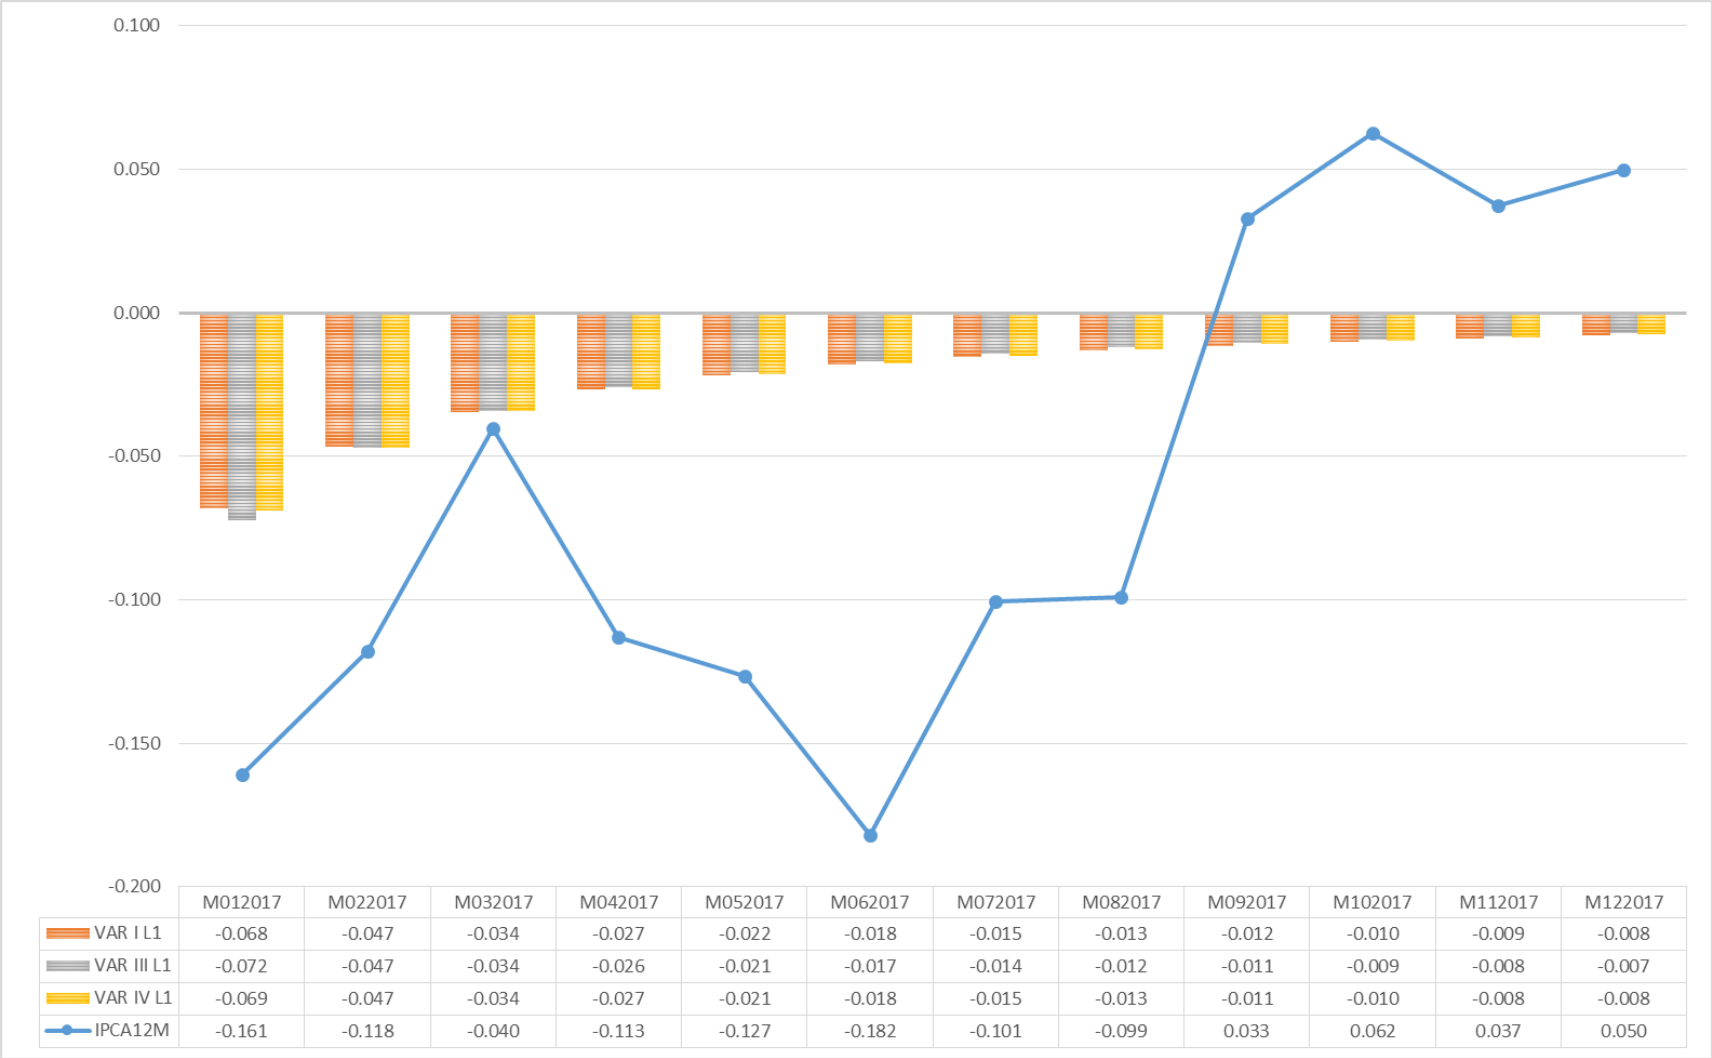

	M012017	M022017	M032017	M042017	M052017	M062017	M072017	M082017	M092017	M102017	M112017	M122017
VAR I L1	-0.068	-0.047	-0.034	-0.027	-0.022	-0.018	-0.015	-0.013	-0.012	-0.010	-0.009	-0.008
VAR III L1	-0.072	-0.047	-0.034	-0.026	-0.021	-0.017	-0.014	-0.012	-0.011	-0.009	-0.008	-0.007
VAR IV L1	-0.069	-0.047	-0.034	-0.027	-0.021	-0.018	-0.015	-0.013	-0.011	-0.010	-0.008	-0.008
IPCA12M	-0.161	-0.118	-0.040	-0.113	-0.127	-0.182	-0.101	-0.099	0.033	0.062	0.037	0.050

Fonte: O autor,2019.

O Gráfico 8 permite a comparação entre o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 12 passos das séries que correspondem aos 3 modelos que possuem menor MSE pelo método dinâmico (VAR I *lag* 1, VAR III *lag* 1 e VAR IV *lag* 1). Ao contrário do método estático, pelo método dinâmico podemos observar que os modelos preditivos se comportam de forma muito semelhante a partir do segundo passo adiante o que faz suas estatísticas MSE serem muito próximas.

Da mesma maneira que realizamos para o horizonte de 12 meses, observa-se naTabela9a previsão mensal de 6 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados individualmente com base no método estático. Ademais, relacionamos as previsões mês a mês da primeira diferença do logaritmo do IPCA acumulado para o horizonte de 12 meses. A última linha da Tabela 9 (MSE) representa a estatística do Erro Quadrático Médio de cada modelo para o horizonte de 6 meses.

Com base na Tabela 9, podemos observar que os 3 modelos que apresentaram as menores estatísticas MSE, em ordem crescente, foram: VAR I 3 *lags*, VAR II 3 *lags* e VAR III 3 *lags*. No Gráfico 9, apresentamos a trajetória das previsões para o horizonte de 6 meses porém apenas representando as séries que correspondem aos 3 modelos que possuem menor estatística MSE pelo método estático e qual foi o retorno do IPCA acumulado por 12 meses.

A Tabela 10 apresenta a previsão mensal de 6 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados individualmente, no entanto, o método utilizado neste caso foi o dinâmico.

O Gráfico 10 permite a comparação entre o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 6 passos adiante das séries que correspondem aos 3 modelos que possuem menor estatística MSE pelo método dinâmico (VAR I *lag* 3, VAR II *lag* 3 e VAR III *lag* 3). Pelo método dinâmico, podemos observar que os modelos preditivos que possuem menor MSE no horizonte de 6 meses são os mesmos que pelo método estático.

Tabela 9– Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método estático (6 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M072017	-0.101	-0.141	-0.145	-0.142	-0.145	-0.145	-0.143	-0.147	-0.148	-0.145	-0.146	-0.148	-0.146
M082017	-0.099	-0.068	-0.057	-0.061	-0.071	-0.061	-0.063	-0.062	-0.053	-0.061	-0.062	-0.058	-0.063
M092017	0.033	-0.098	-0.103	-0.080	-0.102	-0.096	-0.079	-0.096	-0.098	-0.083	-0.101	-0.101	-0.087
M102017	0.062	-0.018	-0.013	-0.024	-0.022	-0.015	-0.022	-0.020	-0.015	-0.024	-0.021	-0.023	-0.026
M112017	0.037	0.025	0.029	0.032	0.020	0.018	0.021	0.022	0.023	0.031	0.020	0.017	0.014
M122017	0.050	-0.006	-0.011	-0.006	-0.011	-0.015	-0.013	-0.013	-0.017	-0.011	-0.011	-0.015	-0.017
MSE		**0.0049**	**0.0053**	**0.0044**	**0.0053**	**0.0051**	**0.0045**	**0.0052**	**0.0054**	**0.0047**	**0.0054**	**0.0057**	**0.0051**

Fonte: O autor, 2019.

Gráfico 9- Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (6 passos à frente)

Fonte: O autor, 2019.

Tabela 10 – Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (6 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M072017	-0.101	-0.141	-0.145	-0.142	-0.145	-0.145	-0.143	-0.147	-0.148	-0.145	-0.146	-0.148	-0.146
M082017	-0.099	-0.117	-0.114	-0.116	-0.122	-0.116	-0.115	-0.121	-0.116	-0.123	-0.119	-0.119	-0.122
M092017	0.033	-0.100	-0.095	-0.084	-0.106	-0.097	-0.087	-0.102	-0.096	-0.091	-0.100	-0.098	-0.096
M102017	0.062	-0.087	-0.081	-0.067	-0.093	-0.086	-0.073	-0.087	-0.082	-0.072	-0.086	-0.082	-0.077
M112017	0.037	-0.076	-0.071	-0.055	-0.082	-0.077	-0.057	-0.076	-0.071	-0.058	-0.074	-0.070	-0.062
M122017	0.050	-0.067	-0.062	-0.047	-0.073	-0.069	-0.049	-0.066	-0.062	-0.049	-0.065	-0.061	-0.048
MSE		**0.0113**	**0.0106**	**0.0084**	**0.0125**	**0.0114**	**0.0089**	**0.0116**	**0.0107**	**0.0092**	**0.0113**	**0.0108**	**0.0097**

Fonte: O autor, 2019.

Gráfico 10- Retorno IPCA acumulado e valores projetados dos 3 modelos VAR com menor MSE com base no método dinâmico: 6 passos à frente

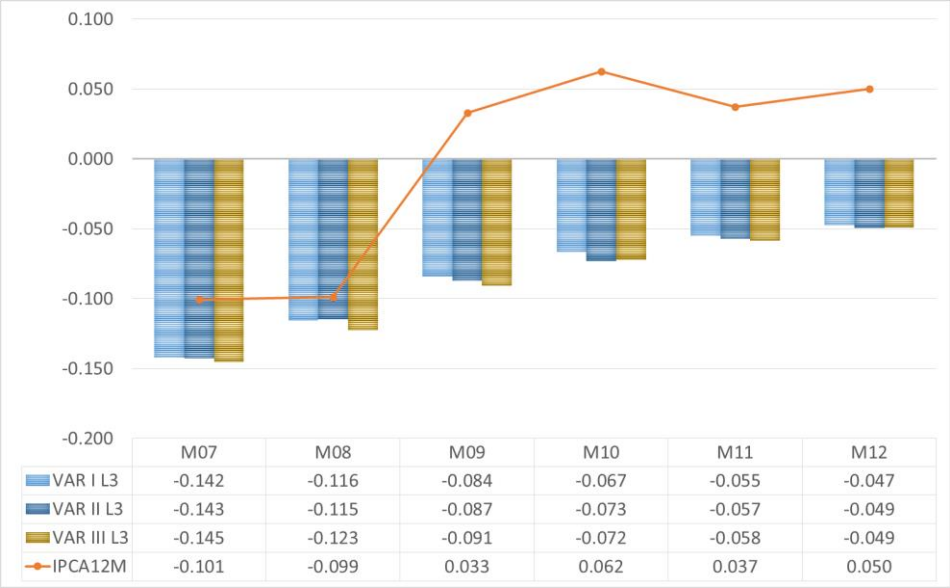

Fonte: O autor, 2019.

Com relação as previsões individuais, na Tabela 11 apresentamos a previsão mensal de 3 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados individualmente com base no método estático, onde podemos observar que os 3 modelos que apresentaram as menores estatísticas MSE, em ordem crescente, foram: VAR I 1 *lag*, VAR I 2 *lags* e VAR IV 1 *lag*. No Gráfico 11, apresentamos a trajetória das previsões para o horizonte de 3 meses porém apenas representando as séries que correspondem aos 3 modelos que possuem menor estatística MSE pelo método estático e o retorno do IPCA acumulado por 12 meses.

A Tabela 12 também apresenta a previsão mensal de 3 passos à frente do retorno do IPCA acumulado (DLNIPCA) por cada um dos modelos VAR estimados individualmente, no entanto, o método utilizado neste caso foi o dinâmico.

O Gráfico 12 permite a comparação entre o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 3 passos adiante das séries que correspondem aos 3 modelos que possuem menor estatística MSE pelo método dinâmico (VAR IV *lag* 1, VAR III *lag* 1 e VAR I *lag* 1).

Tabela 11 – Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método estático (3 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M102017	0.062	-0.011	-0.011	-0.032	-0.015	-0.014	-0.029	-0.013	-0.014	-0.031	-0.013	-0.021	-0.033
M112017	0.037	0.028	0.019	0.028	0.023	0.009	0.019	0.024	0.013	0.028	0.023	0.007	0.012
M122017	0.050	0.000	-0.001	0.009	-0.005	-0.007	0.001	-0.007	-0.007	0.004	-0.005	-0.005	0.000
MSE		0.0027	0.0028	0.0036	0.0031	0.0033	0.0037	0.0030	0.0032	0.0037	0.0030	0.0037	0.0041

Fonte: O autor, 2019.

Gráfico 11- Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método estático (3 passos à frente)

Fonte: O autor, 2019.

Tabela 12 – Retorno IPCA acumulado e previsões individuais pelos modelos VAR com base no método dinâmico (3 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L2	VAR I L3	VAR II L1	VAR II L2	VAR II L3	VAR III L1	VAR III L2	VAR III L3	VAR IV L1	VAR IV L2	VAR IV L3
M102017	0.062	-0.011	-0.011	-0.032	-0.015	-0.014	-0.029	-0.013	-0.014	-0.031	-0.013	-0.021	-0.033
M112017	0.037	-0.031	-0.040	-0.047	-0.037	-0.047	-0.050	-0.030	-0.042	-0.040	-0.030	-0.050	-0.055
M122017	0.050	-0.038	-0.050	-0.054	-0.043	-0.058	-0.063	-0.035	-0.051	-0.047	-0.035	-0.056	-0.065
MSE		**0.0059**	**0.0071**	**0.0090**	**0.0067**	**0.0082**	**0.0096**	**0.0058**	**0.0074**	**0.0080**	**0.0058**	**0.0086**	**0.0103**

Fonte: O autor, 2019.

Gráfico 12- Retorno IPCA acumulado e previsões individuais dos 3 modelos VAR com menor MSE com base no método dinâmico (3 passos à frente)

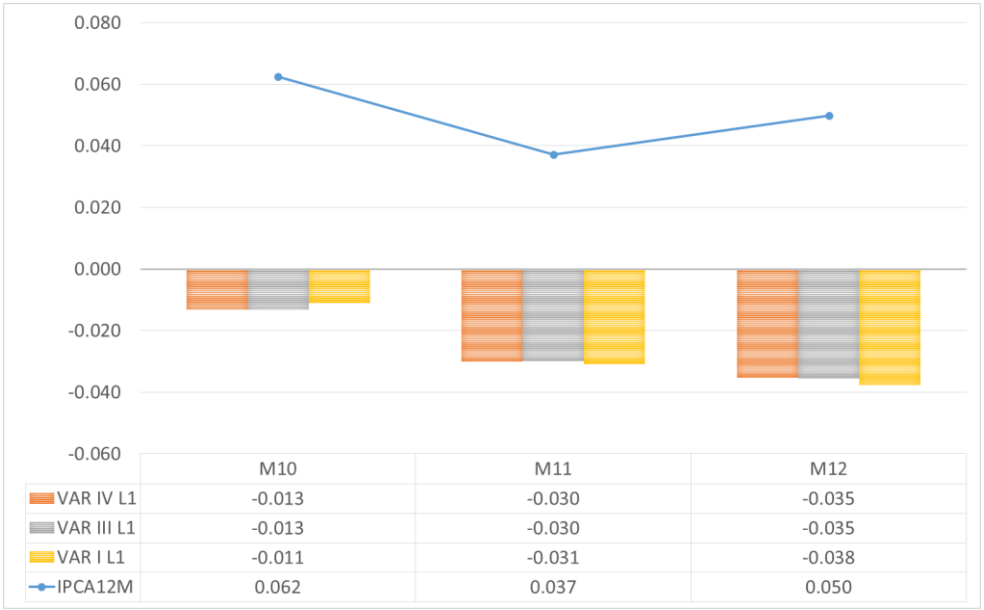

Fonte: O autor, 2019.

5.4 Combinação de Previsões individuais

Nesta seção, apresentamos o resultado das combinações de previsões. Os resultados empíricos que obtivemos pelo método estático para o horizonte de 12 passos adiante quando foram combinadas as previsões de forma a minimizar a estatística Erro Quadrático Médio (MSE) e, simultaneamente, as estatísticas MSE, MAE e MAPE, mediante otimização multiobjetivo com abordagem de programação por metas estão relacionados na Tabela 13.

Através da ferramenta *Solver* do *Excel*, realizamos a combinação dos modelos de modo a minimizar o MSE e obtivemos como solução que o menor erro quadrático médio é obtido pela ponderação de 86% das previsões individuais do modelo VAR II *lag* 3 e 14% das previsões individuais do modelo VAR IV *lag* 3. Na coluna COMB_MSE da Tabela 13 apresentamos a previsão mês a mês das previsões individuais dos VAR que ao serem combinados possuem o menor MSE. Ao calcularmos o erro quadrático médio da previsão COMB_MSE, observamos que esta foi equivalente a obtida pelo VAR II *lag* 3, ou seja, a contribuição do VAR IV *lag* 3 não foi capaz de reduzir significativamente a estatística MSE.

Quando combinamos as previsões individuais visando a minimização das estatísticas MSE, MAE e MAPE, através da ferramenta *Solver* do *Excel*, obtivemos resultado apresentado na última coluna da Tabela 13. No entanto, a ponderação dada como solução é diferente daquela obtida pela minimização apenas do MSE. A combinação de previsões individuais que é capaz de minimizar as 3 estatísticas em conjunto é composta por 64% das previsões do modelo VAR I *lag* 3 e 36% do VAR II *lag* 3. No entanto, a previsão combinada COMB_MSE_MAPE_MAE gera um erro quadrático médio superior do que aquele que prioriza somente a minimização da estatística MSE.

O Gráfico 13 permite a comparação entre o retorno do IPCA acumulado por 12 meses e as previsões de 12 passos adiante do VAR que possui a menor estatística MSE pelo método estático (VAR II *lag* 3), as previsões combinadas COMB_MSE e as previsões combinadas COMB_MSE_MAPE_MAE. Conforme podemos observar pelo gráfico, as projeções 12 passos à frente acompanham a trajetória da série histórica do IPCA.

Pelo método dinâmico, da mesma maneira que para o método estático, realizamos a combinação da previsões individuais dos modelos e obtivemos como solução que o menor MSE é obtido pela ponderação de 51,4% das previsões individuais do modelo VAR I *lag* 1 e 48,6% das previsões individuais do modelo VAR III *lag* 1. Na coluna COMB_MSE da Tabela 14 apresentamos a previsão mês a mês das previsões individuais dos VAR que ao serem combinados possuem o menor MSE pelo método dinâmico. Observamos pelos dados da tabela que a estatística MSE foi equivalente a previsão obtida nos VAR que possuem a menor estatística MSE individualmente. Ou seja, a contribuição dos VAR para minimizar a estatística MSE são muito próximas o que pode ser observado pelo peso atribuído ser de aproximadamente 50% para cada um.

Para a combinação de previsões individuais pela minimização das estatísticas MSE, MAE e MAPE, através da ferramenta *Solver* do *Excel*, obtivemos resultado apresentado na última coluna da Tabela 14. No entanto, a ponderação dada como solução é diferente daquela obtida pela minimização apenas do MSE, assim como ocorreu no método estático.

A combinação de previsões individuais que é capaz de minimizar as 3 estatísticas em conjunto é composta por 87% das previsões do modelo VAR III *lag* 1 e 13% do VAR IV *lag* 1. No entanto, a previsão combinada COMB_MSE_MAPE_MAE gera erro quadrático médio pouco maior do que aquele que prioriza a minimização de MSE somente. Portanto, repetindo o comportamento observado das previsões pelo método estático. Cabe destacar que a combinação que visava minimizar as 3 estatísticas não foi capaz de gerar previsões com MSE menores do que a previsão individual. Isto deve estar associado às restrições representadas pelas 3 estatísticas em conjunto. Ou seja, ao impormos que ocorra a minimização de 3 estatísticas o modelo visa combinar previsões de modo a minimizá-las em conjunto e não somente o erro quadrático médio.

O Gráfico 14 permite a comparação entre o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 12 passos adiante individuais e combinadas. Conforme podemos observar pelo gráfico, as projeções 12 passos à frente possuem menor poder preditivo para acompanhar a trajetória da série histórica do IPCA.

Tabela 13– Retorno IPCA acumulado, previsões individuais dos modelos VAR com menor MSE e previsões combinadas com base no método estático (12 passos à frente)

MESES	IPCA12M	VAR I L3	VAR II L3	VAR IV L3	COMB_MSE	COMB_MSE_MAPE_MAE
M012017	-0.161	-0.070	-0.064	-0.069	-0.065	-0.068
M022017	-0.118	-0.108	-0.101	-0.110	-0.103	-0.106
M032017	-0.040	-0.076	-0.071	-0.078	-0.072	-0.075
M042017	-0.113	-0.032	-0.032	-0.036	-0.032	-0.032
M052017	-0.127	-0.079	-0.084	-0.075	-0.083	-0.081
M062017	-0.182	-0.075	-0.083	-0.092	-0.085	-0.078
M072017	-0.101	-0.131	-0.131	-0.136	-0.132	-0.131
M082017	-0.099	-0.058	-0.059	-0.060	-0.059	-0.059
M092017	0.033	-0.068	-0.069	-0.072	-0.069	-0.068
M102017	0.062	-0.023	-0.018	-0.023	-0.019	-0.021
M112017	0.037	0.034	0.022	0.019	0.021	0.029
M122017	0.050	-0.002	-0.010	-0.012	-0.010	-0.005
MSE		**0.00440**	**0.00431**	**0.00434**	**0.00431**	**0.00436**

Fonte: O autor, 2019.

Tabela 14 – Retorno IPCA acumulado, previsões individuais dos modelos VAR com menor MSE e previsões combinadas com base no método dinâmico (12 passos à frente)

MESES	IPCA12M	VAR I L1	VAR III L1	VAR IV L1	COMB_MSE	COMB_MSE_MAPE_MAE
M012017	-0.161	-0.068	-0.072	-0.069	-0.070	-0.072
M022017	-0.118	-0.047	-0.047	-0.047	-0.047	-0.047
M032017	-0.040	-0.034	-0.034	-0.034	-0.034	-0.034
M042017	-0.113	-0.027	-0.026	-0.027	-0.026	-0.026
M052017	-0.127	-0.022	-0.021	-0.021	-0.021	-0.020
M062017	-0.182	-0.018	-0.017	-0.018	-0.018	-0.016
M072017	-0.101	-0.015	-0.014	-0.015	-0.015	-0.014
M082017	-0.099	-0.013	-0.012	-0.013	-0.013	-0.012
M092017	0.033	-0.012	-0.011	-0.011	-0.011	-0.010
M102017	0.062	-0.010	-0.009	-0.010	-0.010	-0.009
M112017	0.037	-0.009	-0.008	-0.008	-0.008	-0.008
M122017	0.050	-0.008	-0.007	-0.008	-0.008	-0.007
MSE		**0.00719**	**0.00719**	**0.00720**	**0.00719**	**0.00722**

Fonte: O autor, 2019.

Gráfico 13 - Retorno IPCA acumulado, previsões individuais do modelo VAR com menor MSE e previsões combinadas com base no método estático (12 passos à frente)

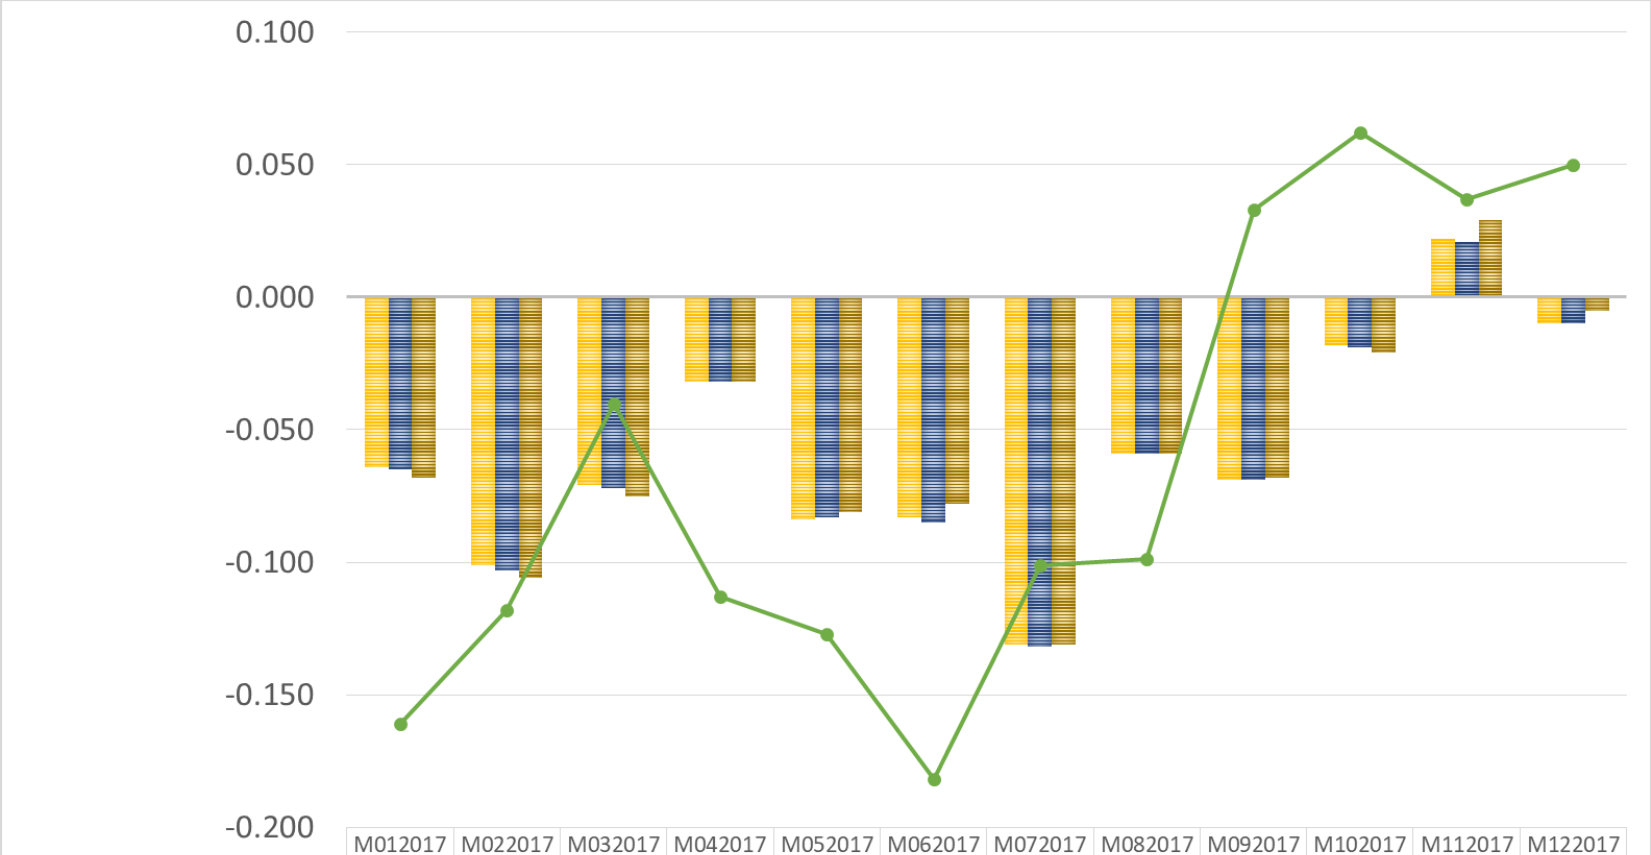

	M012017	M022017	M032017	M042017	M052017	M062017	M072017	M082017	M092017	M102017	M112017	M122017
VAR II L3	-0.064	-0.101	-0.071	-0.032	-0.084	-0.083	-0.131	-0.059	-0.069	-0.018	0.022	-0.010
COMB_MSE	-0.065	-0.103	-0.072	-0.032	-0.083	-0.085	-0.132	-0.059	-0.069	-0.019	0.021	-0.010
COMB_MSE_MAPE_ MAE	-0.068	-0.106	-0.075	-0.032	-0.081	-0.078	-0.131	-0.059	-0.068	-0.021	0.029	-0.005
IPCA12M	-0.161	-0.118	-0.040	-0.113	-0.127	-0.182	-0.101	-0.099	0.033	0.062	0.037	0.050

Fonte: O autor, 2019.

Gráfico 14- Retorno IPCA acumulado, previsões individuais dos 2 modelos VAR com menor MSE e previsões combinadas com base no método dinâmico (12 passos à frente)

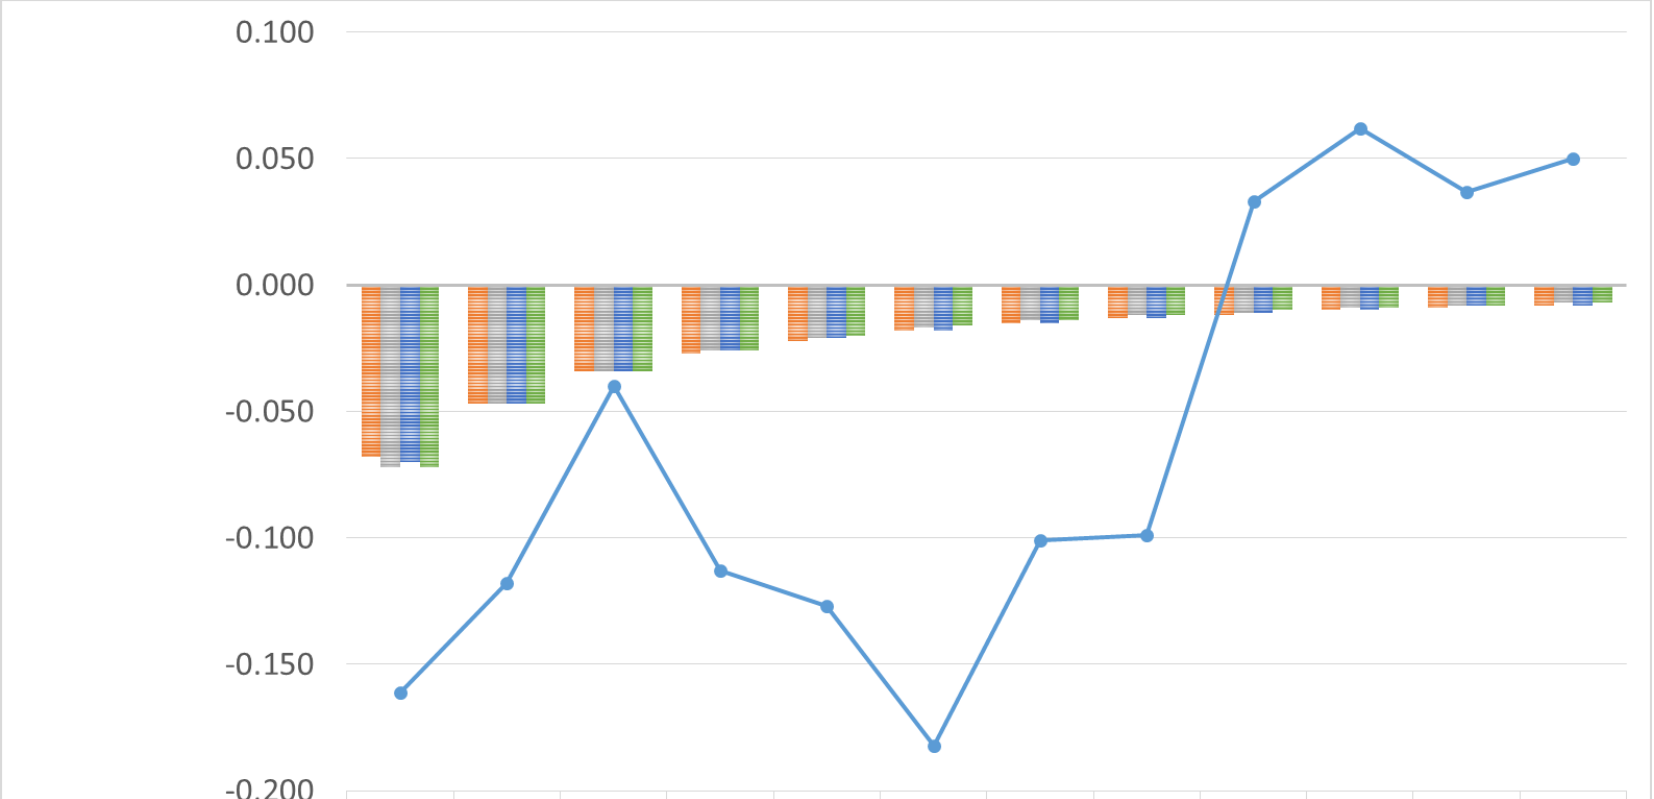

	M012017	M022017	M032017	M042017	M052017	M062017	M072017	M082017	M092017	M102017	M112017	M122017
VAR I L1	-0.068	-0.047	-0.034	-0.027	-0.022	-0.018	-0.015	-0.013	-0.012	-0.010	-0.009	-0.008
VAR III L1	-0.072	-0.047	-0.034	-0.026	-0.021	-0.017	-0.014	-0.012	-0.011	-0.009	-0.008	-0.007
COMB_MSE	-0.070	-0.047	-0.034	-0.026	-0.021	-0.018	-0.015	-0.013	-0.011	-0.010	-0.008	-0.008
COMB_MSE_MAPE_ MAE	-0.072	-0.047	-0.034	-0.026	-0.020	-0.016	-0.014	-0.012	-0.010	-0.009	-0.008	-0.007
IPCA12M	-0.161	-0.118	-0.040	-0.113	-0.127	-0.182	-0.101	-0.099	0.033	0.062	0.037	0.050

Fonte: O autor, 2019.

Os resultados para a análise das previsões pelo método estático para o horizonte de 6 passos adiante quando combinamos as previsões individuais estão relacionados na Tabela 15.

No sentido das previsões possibilitarem a minimização do MSE, através do *Solver*, realizamos a combinação dos modelos e obtivemos como solução que o menor MSE é obtido por 100% das previsões individuais do modelo VAR I *lag* 3. Na coluna COMB_MSE da Tabela 15 apresentamos a previsão mês a mês calculada de modo a minimizar o erro quadrático médio das previsões individuais. A previsão combinada COMB_MSE foi equivalente a obtida pelo VAR I *lag* 3, ou seja, dentre as 12 modelagens VAR para o horizonte de 6 meses à frente o VAR I *lag* 3 é capaz de realizar sem necessidade de combinar as previsões que retornam o menor MSE. A previsão combinada COMB_MSE_MAPE_MAE também foi gerada 100% pelo VAR I *lag* 3. Com isso, foi capaz de minimizar as 3 estatísticas em conjunto.

O Gráfico 15 apresenta o retorno do IPCA acumulado por 12 meses e a trajetória das previsões 6 passos adiante. Além disso, incluímos o erro absoluto das previsões deste modelo sendo possível observar que nos 6 passos adiante o modelo foi capaz de prever com erro absoluto próximo a 0,1 o que afirma a capacidade preditiva no curto prazo dos modelos.

Tabela 15- Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método estático (6 passos à frente)

MESES	IPCA12M	VAR I L3	COMB_MSE	COMB_MSE_MAPE_MAE
M072017	-0.101	-0.142	-0.142	-0.142
M082017	-0.099	-0.061	-0.061	-0.061
M092017	0.033	-0.080	-0.080	-0.080
M102017	0.062	-0.024	-0.024	-0.024
M112017	0.037	0.032	0.032	0.032
M122017	0.050	-0.006	-0.006	-0.006
MSE		**0.0044**	**0.0044**	**0.0044**

Fonte: O autor, 2019.

Gráfico 15- Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método estático (6 passos à frente)

	M07	M08	M09	M10	M11	M12
ERRO ABSOLUTO	0.042	0.038	0.113	0.087	0.005	0.056
IPCA12M	-0.101	-0.099	0.033	0.062	0.037	0.050
COMB_MSE_MAPE_MAE	-0.142	-0.061	-0.080	-0.024	0.032	-0.006

Fonte: O autor, 2019.

Pelo método dinâmico para o horizonte de 6 passos adiante apresentamos as previsões de forma a minimizar a estatística Erro Quadrático Médio e de maneira a minimizar, simultaneamente, as estatísticas MSE, MAE e MAPE, mediante otimização multiobjetivo na Tabela 16.

Para o método estático realizamos para o método dinâmico a combinação dos modelos e obtivemos como solução que o menor MSE é obtido somente pelo modelo VAR I *lag*3. Portanto, nenhuma combinação dos 12 modelos no período amostral tem MSE menor do que o VAR I *lag* 3 individualmente. Da mesma maneira que para a combinação de previsões individuais pela minimização das estatísticas MSE, MAE e MAPE, através da ferramenta *Solver* do *Excel*, obtivemos resultado apresentado na última coluna da Tabela 16. O comportamento observado das previsões foi equivalente ao obtido pelo método estático.

O Gráfico16 apresenta o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 6 passos adiante. Além disso, incluímos o erro absoluto das previsões deste modelo e foi possível observar nos passos6adiante o modelo foi capaz de prever com erro absoluto próximo a 0,1 como ocorreu nas projeções através do método estático.

Tabela 16- Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método dinâmico (6 passos à frente)

MESES	IPCA12M	VAR I L3	COMB_MSE	COMB_MSE_MAPE_MAE
M072017	-0.101	-0.142	-0.142	-0.142
M082017	-0.099	-0.116	-0.116	-0.116
M092017	0.033	-0.084	-0.084	-0.084
M102017	0.062	-0.067	-0.067	-0.067
M112017	0.037	-0.055	-0.055	-0.055
M122017	0.050	-0.047	-0.047	-0.047
MSE		**0.0084**	**0.0084**	**0.0084**

Fonte: O autor, 2019.

Gráfico 16- Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método dinâmico (6 passos à frente)

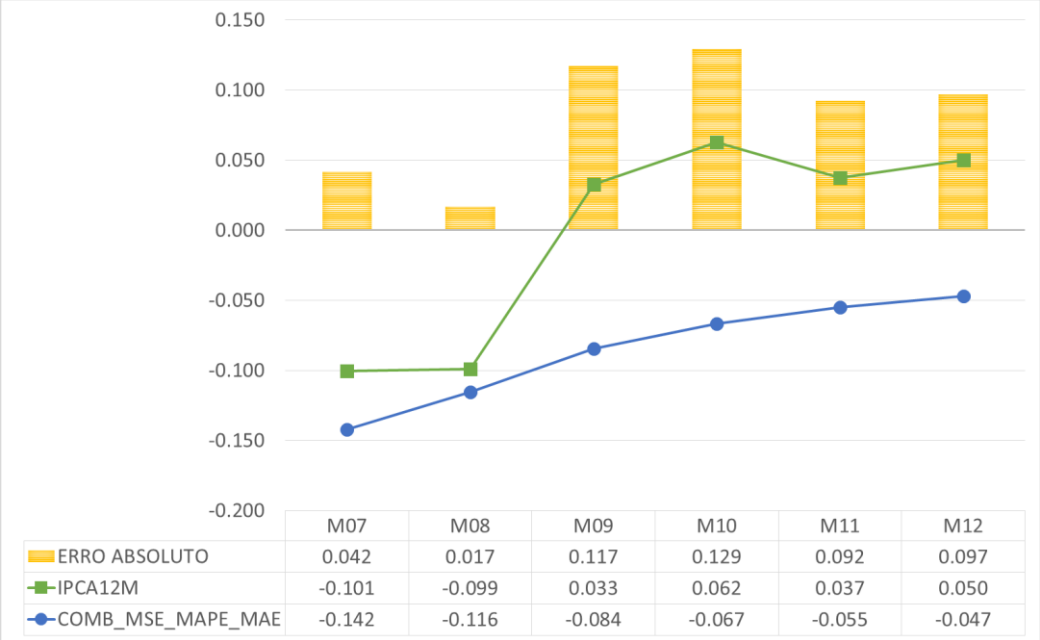

Fonte: O autor, 2019.

Os resultados empíricos que obtivemos pelo método estático para o horizonte de 3 passos adiante quando combinamos as previsões estão relacionados na Tabela 17.

Para que houvesse a minimização do erro quadrático médio, através da ferramenta *Solver* do *Excel*, realizamos a combinação dos modelos e obtivemos como solução que o menor MSE é obtido por 100% das previsões individuais do modelo VAR I *lag* 1. Na coluna COMB_MSE da Tabela 17 apresentamos a previsão mês a mês combinada utilizando a estatística MSE. Ao calcularmos o MSE da previsão COMB_MSE, observamos que esta foi equivalente a obtida pelo VAR I *lag* 1, ou seja, dentre as 12 modelagens VAR para o horizonte de 3 meses à frente o VAR I *lag* 1 é

capaz de realizar sem combinar com os outros VAR as previsões que retornam o menor MSE. No entanto, pela otimização multiobjetivo quando definimos como objetivo a minimização das 3 estatísticas (MAPE, MAE e MSE) em conjunto, as previsões foram geradas utilizando 79% das projeções do VAR I *lag* 1 e 23% do VAR I *lag* 3. Devemos aqui destacar que o VAR I *lag* 3 não possui as previsões individuais com menor MSE, porém foi capaz de combinar com as previsões do VAR I lag 1 produzir previsões que aproximam o resultado da previsão combinada que minimiza o MSE. O Gráfico 17 apresenta o retorno do IPCA acumulado por 12 meses e a trajetória das previsões individuais e combinadas 3 passos adiante.

Tabela 17- Retorno IPCA acumulado, previsões individual dos modelo VAR com menor MSE e previsões combinadas com base no método estático (3 passos à frente)

MESES	IPCA12M	VAR I L1	VAR I L3	COMB_MSE	COMB_MSE_MAPE_MAE
M102017	0.062	-0.011	-0.032	-0.011	-0.016
M112017	0.037	0.028	0.028	0.028	0.028
M122017	0.050	0.000	0.009	0.000	0.002
MSE		**0.0027**	**0.0036**	**0.0027**	**0.0028**

Fonte: O autor, 2019.

Gráfico 17- Retorno IPCA acumulado e previsão com base no método estático: 3 passos à frente

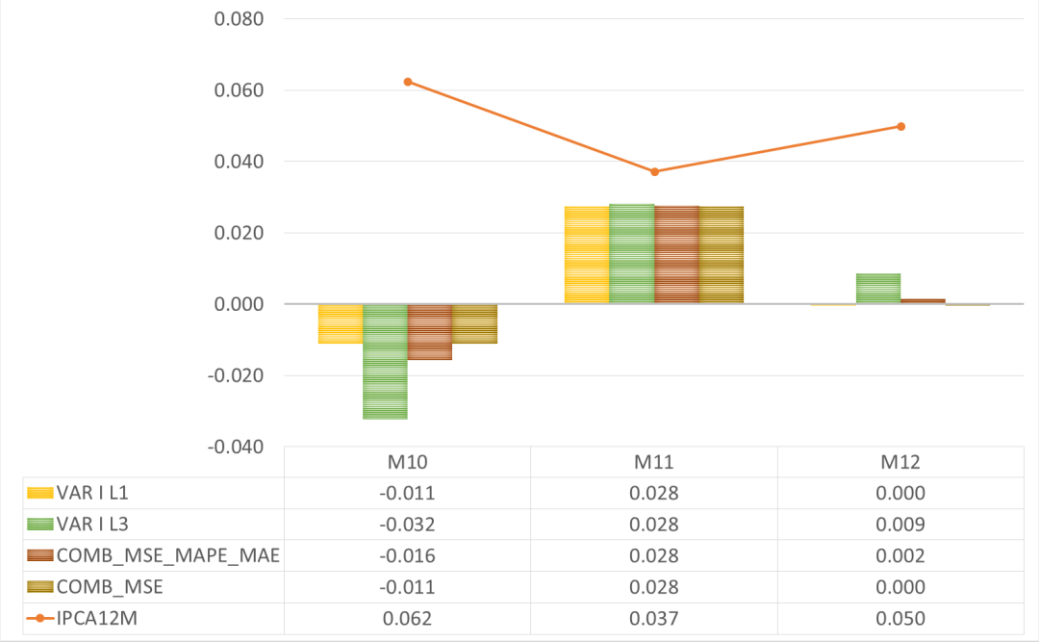

Fonte: O autor, 2019.

Pelo método dinâmico para o horizonte de 3 passos adiante quando combinamos as previsões estão relacionados na Tabela 18. Da mesma maneira que

para o método estático realizamos para o método dinâmico a combinação dos modelos e obtivemos como solução que o menor MSE é obtido somente pelo modelo VAR IV *lag* 1. Portanto, nenhuma combinação dos 12 modelos gera MSE menor do que aquele modelo individualmente, da mesma maneira que para a minimização das estatísticas MSE, MAE e MAPE. Através da ferramenta *Solver*, obtivemos resultado apresentado na última coluna da Tabela 18. A ponderação dada como solução é a mesma obtida pela minimização apenas do MSE e para as 3 estatísticas em conjunto.

O Gráfico 18 apresenta o retorno do IPCA acumulado por 12 meses e a trajetória das previsões de 3 passos adiante. Além disso, incluímos o erro absoluto das previsões deste modelo e foi possível observar que o modelo prevê com erro inferior a 0,1 conforme havíamos observado com 6 passos adiante.

Tabela 18- Retorno IPCA acumulado, previsão individual do modelo VAR com menor MSE e previsões combinadas com base no método dinâmico (3 passos à frente)

MESES	IPCA12M	VAR IV L1	COMB_MSE	COMB_MSE_MAPE_MAE
M102017	0.062	-0.013	-0.013	-0.013
M112017	0.037	-0.030	-0.030	-0.030
M122017	0.050	-0.035	-0.035	-0.035
MSE		**0.0058**	**0.0058**	**0.0058**

Fonte: O autor, 2019.

Gráfico 18- Retorno IPCA acumulado, erro absoluto e previsão combinada com base no método dinâmico (3 passos à frente)

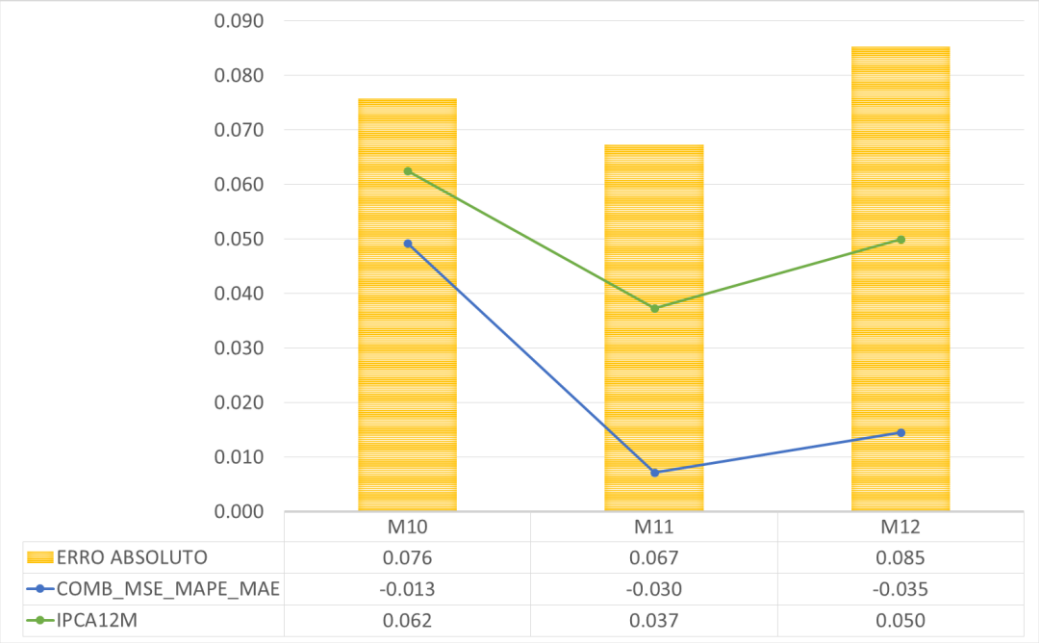

Fonte: O autor, 2019.

5.5 Avaliação de Previsões

Após a geração das previsões individualmente e de maneira combinada por cada um dos modelos VAR, utilizaremos os indicadores de performance de modelos utilizados, a partir de ferramentas estatísticas a fim de subsidiar um julgamento das capacidades preditivas.

As Avaliações de Acurácia (*Evaluating forecasting accuracy*) das previsões foram obtidas com base nas estatísticas raiz quadrada erro quadrático médio (RMSE), o erro absoluto médio (MAE) e o erro quadrático médio (MAPE). A avaliação baseadas nestas 3 estatísticas possui as seguintes características: trata-se de uma medida de avaliação comum a previsões, possibilita o julgamento com base na minimização da previsão, o desvio da inflação ao quadrado é provavelmente muito próximo a função de perda estimada pelo Banco Central, além de permitir uma apresentação mais compacta e passível de comparação entre modelos.

Estas avaliações foram mensuradas tanto em termos absolutos quanto em termos relativos. Em termos absolutos, apenas foram aplicadas as fórmulas apresentadas no capítulo 3; quanto em termos relativos, comparamos a razão de cada uma das três estatísticas com aquelas estatísticas de um modelo "*Naïve*". As informações de acurácia das previsões em termos absolutos são apresentadas de modo que os modelos com valores próximos a zero possuem maior acurácia que os demais. Em termos relativos, quando um modelo apresentar resultado maior do que 1 isto significa que o modelo "*Naïve*" tem resultados mais acurados.

Através do modelo "*Naïve"* supomos não alteração da taxa de inflação para um passo à frente, i.e., $\mathrm{E}(\pi_{t+h}|\pi_t = \pi_t)$sendo os horizontes de previsão *h* e π_t o IPCA acumulado em 12meses. Ou seja, a grosso modo, é o mesmo que dizer que a inflação do mês atual é igual a inflação do mês anterior. Desta maneira, utilizamos o modelo "*Naïve*" como modelo referência ("*benchmark*"), uma vez que se um modelo possui acurácia inferior para prever a inflação do que a mera reprodução da taxa de inflação do mês anterior (modelo "*Naïve*") em pouco ele contribui para a tarefa de previsão.

Na Tabela 19, que traz as 3 estatísticas absolutas e relativas dos modelos de previsão pelos métodos dinâmico e estático para os 3 horizontes preditivos, podemos confirmar que os modelos VAR possuem elevada capacidade de predição no curto prazo.

Tabela 19 – Avaliação da Acurácia dos modelos 3, 6 e 12 passos à frente

		PREVISÕES À FRENTE					
		3 MESES	6 MESES	12 MESES	3 MESES	6 MESES	12 MESES
MODELOS	**MÉTODO PREDITIVO**	**RMSE**	**RMSE**	**RMSE**	**RMSE RELAT.**	**RMSE RELAT.**	**RMSE RELAT.**
NAÏVE	-	0.139	0.188	0.438	1.000	1.000	1.000
VAR INDIV COM MENOR MSE	ESTÁTICO	0.139	0.169	0.244	1.004	0.898	0.555
COMB_MSE	ESTÁTICO	0.139	0.169	0.243	1.004	0.898	0.554
COMB_MSE_MAPE_MAE	ESTÁTICO	0.143	0.169	0.242	1.029	0.898	0.553
VAR INDIV COM MENOR MSE	DINÂMICO	0.208	0.236	0.312	1.500	1.257	0.712
COMB_MSE	DINÂMICO	0.208	0.236	0.311	1.500	1.257	0.710
COMB_MSE_MAPE_MAE	DINÂMICO	0.208	0.236	0.311	1.500	1.257	0.710
MODELOS	**MÉTODO PREDITIVO**	**MAE**	**MAE**	**MAE**	**MAE RELAT.**	**MAE RELAT.**	**MAE RELAT.**
NAÏVE	-	0.137	0.172	0.360	1.000	1.000	1.000
VAR INDIV COM MENOR MSE	ESTÁTICO	0.121	0.146	0.202	0.887	0.847	0.560
COMB_MSE	ESTÁTICO	0.121	0.146	0.202	0.887	0.847	0.560
COMB_MSE_MAPE_MAE	ESTÁTICO	0.123	0.146	0.200	0.901	0.847	0.555
VAR INDIV COM MENOR MSE	DINÂMICO	0.207	0.213	0.271	1.515	1.236	0.751
COMB_MSE	DINÂMICO	0.207	0.213	0.270	1.515	1.236	0.750
COMB_MSE_MAPE_MAE	DINÂMICO	0.207	0.213	0.270	1.515	1.236	0.750
MODELOS	**MÉTODO PREDITIVO**	**MAPE**	**MAPE**	**MAPE**	**MAPE RELAT.**	**MAPE RELAT.**	**MAPE RELAT.**
NAÏVE	-	0.049	0.065	0.099	1.000	1.000	1.000
VAR INDIV COM MENOR MSE	ESTÁTICO	0.043	0.055	0.058	0.889	0.848	0.590
COMB_MSE	ESTÁTICO	0.043	0.055	0.058	0.889	0.848	0.591
COMB_MSE_MAPE_MAE	ESTÁTICO	0.044	0.055	0.058	0.905	0.848	0.586
VAR INDIV COM MENOR MSE	DINÂMICO	0.073	0.078	0.079	1.507	1.210	0.802
COMB_MSE	DINÂMICO	0.073	0.078	0.079	1.507	1.210	0.801
COMB_MSE_MAPE_MAE	DINÂMICO	0.073	0.078	0.079	1.507	1.210	0.802

Fonte: O autor, 2019.

Além disso, observamos a inferioridade de previsão do método dinâmico em comparação ao método estático. Nos horizontes de tempo maiores (6 e 12 passos adiante) foi possível observar que os modelos VAR, tanto nas previsões individuais quanto combinadas, foram capazes de geram melhores previsões comparativamente ao modelo *Naïve*. Isto possivelmente está associado a pequena variação observada

no período de 3 meses, i.e., em pequenos horizontes a inflação no período *t* é muito próxima do período *t+1*.

No Quadro 10 sumariamos os métodos, modelagens e horizontes com menor Erro quadrático médio. Dentro todas as modelagens observamos que aproximadamente 50% das previsões mais acuradas foram geradas pelo VAR Ademais, todas as previsões individuais e combinações de previsões com menor erro quadrado médio foram obtidas pelos VAR com 3 defasagens ou 1 defasagem.

Quadro 10– Resumo de modelagens pelos menores Erros Quadráticos Médios

MODELOS	MÉTODO	HORIZONTE	ORDENAÇÃO CRESCENTE DE VAR COM MENOR MSE
PREVISÕES INDIVIDUAIS	ESTÁTICO	12 MESES	VAR II L3, VAR IV L3, VAR I L3
	DINÂMICO	12 MESES	VAR I L3, VAR III L1, VAR IV L1
	ESTÁTICO	6 MESES	VAR I L3, VAR II L3, VAR III L3
	DINÂMICO	6 MESES	VAR I L3, VAR II L3, VAR III L3
	ESTÁTICO	3 MESES	VAR I L1, VAR I L2, VAR IV L1
	DINÂMICO	3 MESES	VAR IV L1, VAR III L1, VAR I L1
PREVISÕES COMBINADAS MSE	ESTÁTICO	12 MESES	86% VAR II L3, 14% VAR IV L3
	DINÂMICO	12 MESES	51% VAR I L1, 49% VAR III L1
	ESTÁTICO	6 MESES	100% VAR I L3
	DINÂMICO	6 MESES	100% VAR I L3
	ESTÁTICO	3 MESES	100% VAR I L1
	DINÂMICO	3 MESES	100% VAR IV L1
PREVISÕES COMBINADAS MSE MAPE MAE	ESTÁTICO	12 MESES	64% VAR I L3, 36% VAR II L3
	DINÂMICO	12 MESES	87% VAR III L1, 13% VAR IV L3
	ESTÁTICO	6 MESES	100% VAR I L3
	DINÂMICO	6 MESES	100% VAR I L3
	ESTÁTICO	3 MESES	79% VAR I L1, 21% VAR I L3
	DINÂMICO	3 MESES	100% VAR IV L1

Fonte: O autor, 2019.

Em face disso, sob a necessidade de parcimônia para especificar qual VAR modelar para prever a inflação brasileira (IPCA) podemos sugerir pelos resultados encontrados que dentre todos os VAR deste trabalho e períodos, métodos e horizontes o VAR I com 3 defasagens através do método estático foi capaz de gerar melhores previsões.

No entanto, todos os VAR modelados nos três tipos de arranjos de defasagens foram capazes de gerar previsões acuradas em relação as demais em algum horizonte ou método. Contudo, sabemos, conforme relataram Carlos e Marçal (2013) e Caldeira, et al. (2015), para a previsão da inflação (IPCA) sob diferentes metodologias não há evidências de que não exista um modelo que supere todos os

demais em todos os horizontes de previsão. Portanto, entendemos que identificar uma única especificação capaz de abranger a capacidade preditiva de todas as demais em todos os métodos, horizontes de previsão e variáveis de interesse seja uma afirmação exageradamente forte e desprovida de compromisso científico.

6 - CONSIDERAÇÕES FINAIS

Em face da importância em prever a inflação, buscou-se com esta dissertação analisar empiricamente e apresentar contribuições que viabilizem melhorias na capacidade preditiva dos modelos de Vetores Autorregressivos(VAR).

Para atingir este objetivo, elaborou-se quatro modelos de Vetores Autorregressivos (VAR) com até 3 defasagens capazes de estimar o índice de preços ao consumidor amplo (IPCA) acumulado em 12 meses. Em seguida, calculou-se previsões dos quatro modelos VAR estimados individualmente pelos métodos estático e dinâmico.

Em complemento, foram geradas combinações das projeções individuais considerando apenas a minimização dos erros quadráticos médios. Além disso, pela combinação linear calculada pela programação matemática (PPM) multiobjetivo MINIMAX, geramos projeções combinadas da inflação capazes de minimizar o desvio médio máximo referentes as estatísticas: erro quadrático médio (MSE), erro médio absoluto (MAE) e erro médio percentual absoluto (MAPE).

No intuito de verificar se a combinação de previsões *vis-à-vis* a previsões individuais oriundas dos modelos VAR pelos métodos estático e dinâmico nos horizontes preditivos de 12, 6 e 3 meses eram capazes de gerar melhor acurácia de projeções para a inflação de curto prazo, as projeções foram comparadas a um modelo *Naïve* considerado como modelo referência (*benchmark*) para nossas análise de capacidade preditiva do modelos individuais e combinados.

Os resultados deste trabalho nos apontam que, em média, pelo método estático, as previsões combinadas de inflação calculadas pela combinação de previsões que minimizam o erro quadrático médio (MSE) e as 3 estatísticas (MAPE, MAE e MSE) superam um modelo *Naïve* usado como referência (“benchmark”) e o modelo VAR de previsão individual com maior acurácia. Isso é observado principalmente para previsões com 6 e 12 passos à frente. Pelo método dinâmico, no horizonte de 12 meses as previsões foram mais acuradas que àqueles do modelo referência.

Com isso, entendemos que as previsões combinadas são mais acuradas do que as individuais surgem devido ao fato dos desvios de previsão são diversificados entre os diferentes modelos VAR. Segundo, as combinações de previsões não são

dependentes de uma única especificação de modelo VAR, o que as tornam menos sensíveis a erros de especificação. Por fim, as previsões combinadas de VAR são geralmente baseadas em mais informações do que as previsões individuais.

Em resumo, entendemos que a combinação de previsões pela programação matemática (PPM) multiobjetivo MINIMAX é capaz de gerar projeções com desempenho superior ao obtido pelas previsões individuais com séries fora da amostra, uma vez que cada modelo VAR fornece informações distintas acerca da relação entre as variáveis ao longo do tempo.

Apesar dos resultados obtidos com esta pesquisa terem sido satisfatórios, devemos esclarecer que utilizamos neste trabalho apenas sete variáveis com ênfase na inflação brasileira. A transmissão monetária de outros países e períodos pode sofrer alteração na importância de variáveis o que sugeriria a inclusão de outras como preços de importados, índices da atividade real, diferentes taxas de juros e agregados monetário, por exemplo.

Além disso, estimamos os modelos VAR no recorte temporal de 15 anos. Com isso, não examinamos se os resultados apresentariam outro comportamento em horizontes menores de tempo. Estes fracionamentos amostrais levariam a uma grande quantidade de modelos e testes tanto em nível quanto em diferença bem como a análise de cointegração para verificação da possibilidade de uso de modelos de correção de erros (VECM).

Para futuras pesquisas análises empíricas relativas ao tema de previsão de inflação e combinação de previsões de inflação sugerimos a investigação dos resultado obtidos neste trabalho em outros países e em período amostral diferente, além da combinação pela diversificação de modelos preditivos. Ou seja, investigar se a combinação de modelos univariados (puramente estatísticos) com modelos estruturais multivariados baseados na teoria econômica podem geram maior acurácia de previsões. Além disso, sugerimos o desenvolvimento de um teste de acurácia que, a partir da programação matemática (PPM) multiobjetivo MINIMAX, seja capaz de combinar previsões e definir quais possuem maior peso na geração de previsão combinada com melhor capacidade preditiva que as demais.

REFERÊNCIAS

ABREU, V.C. *Regime de Metas no Brasil e Previsão de Inflação*: Acurácia e Encompassing. Dissertação (Mestrado em Economia Aplicada) - Pós-graduação em Economia Aplicada, Universidade Federal de Juiz de Fora, 2015.

AIOLFI, M.; TIMMERMANN, A. Persistence in forecasting performance and conditional combination strategies. **Journal of Econometrics**, v. 135, p. 31-53, 2006.

ALENCAR, B.K. *Modelos de Previsão da Inflação*: Uma Análise comparativa no curto prazo. 2006. 65 f. Dissertação (Mestrado profissionalizante em Economia) – Pós-graduação em Economia, Instituto Brasileiro de Mercado de Capitais (IBMEC), 2006.

ANG, A., BEKAERT, G., WEI, M. Do Macro Variables, Asset Markets or Surveys Forecast Inflation Better? **National Bureau of Economic Research** Working Paper Series no. 11538, 2005.

AOUNI, B. KETTANI, O. Goal programming model: a glorious history and a promising future. **European Journal Of Operational Research**, 133, p. 225-231. 2001.

ARRUDA, E. F., FERREIRA, R. T. e CASTELAR, I. Modelos lineares e não lineares da curva de Phillips para previsão da taxa de inflação no Brasil. **Revista Brasileira de Economia**, 65(3), p. 237–252. 2011. Disponível em: <http://bibliotecadigital.fgv.br/ojs/index.php/rbe/article/view/1523> Acesso em: 28 jan. 2018.

ATKESON, A.; OHANIAN, L. E. Are Phillips curves useful for forecasting inflation? Federal Reserve Bank of Minneapolis, **Quarterly Review**, v. 25:1, p. 2–11, 2001.

BANCO CENTRAL DE CHILE (Chile). Modelos Macroeconómicos y Proyecciones del Banco Central de Chile. Santiago. Ago., 2003.

BANERJEE, A., MARCELLINO, M. Are There Any Reliable Leading Indicators for U.S. Inflation and GDP Growth?,**European University Institute**, Working Paper, Nov. 2002.

BATES, J. M.; GRANGER, C. W. J. Combination Forecasts. **Operations ResearchQuarterly**, v. 20, n. 4, p. 451-468, 1969.

BCB - BANCO CENTRAL DO BRASIL (Brasil). Avaliação das Projeções de Inflação do Banco Central do Brasil. In: Relatório de Inflação, BCB, Mar.2003.

_____. Revisão dos Modelos de Vetores Autorregressivos com Fundamentação Econômica – 2012. In: Relatório de Inflação, BCB, Set., 2012.

_____. Revisão dos Modelos de Vetores Autorregressivos Estatísticos – 2012. In: Relatório de Inflação, BCB, Mar., 2013.

BERNANKE, B.S. On the predictive power of interest rates and interest rate spreads. **New England Economic Review.** Nov–Dez: p. 51–61. 1990

BoE - BANK OF ENGLAND (Inglaterra). *Economic Models at the Bank of England* Londres. Abr., 1999.

BRAVE, S., FISHER J D.M. In Search of a Robust Inflation Forecast, Federal Reserve Bank of Chicago,**Economic Perspectives**, p.12-31, 2004.

BUENO, R. L. S. **Econometria de séries temporais.** São Paulo: Cengage Learning, 2. ed. 2015.

CAETANO, S.M.; SILVA, G. E. S. Disagreement, Superior Predicting Ability, And Persistence: The Expectations Of Brazilian Inflation. Juiz de Fora: FE/UFJF, Texto para Discussão, n.20, 2009.

CALDEIRA, João F.; MOURA, Guilherme V.; SANTOS, André A. P.. Previsões Macroeconômicas Baseadas em Modelos TVP-VAR: Evidências Para o Brasil. **Rev. Bras. Econ**., Rio de Janeiro , v. 69, n. 4, p. 407-428, Dec. 2015 . Disponível em: < http://ref.scielo.org/xvssgp>. Acesso em: 28 jan. 2018.

CARLOS, T. C., MARÇAL, E. F. Forecasting Brazilian inflation by its aggregate and disaggregated data: A test of predictive power by forecast horizon. **FGV-SP**, Working Paper n.346, Dez.2013, São Paulo. Disponível em: <http://hdl.handle.net/10438/11338> Acesso em: 28 jan. 2018.

CARVALHO, L. M., SOUZA J. R. C. J. Modelo para Previsão de Inflação. **Boletim de Conjuntura** 72, IPEA, Mar. 2006.

CECCHETTI, S. G. Inflation Indicators and Inflation Policy. National Bureau of Economic Research, **Macroeconomics Annual**, 10 (1995), p. 189-219, 1995.

CECCHETTI, S. G., CHU, R.S., STEINDEL, C. The Unreliability of InflationIndicators. Federal Reserve Bank of New York, **Current Issues in Economics and Finance**, nº6(4), p. 1-6, 2000.

CECCHETTI, S.G.; HOOPER, P., KASMAN, B.C., SCHOENHOLTZ, K.L., WATSON,M.W. Understanding the evolving inflation process. **U.S. Monetary Policy Forum**, 2007.

CHAN, J.C.C. Moving Average Stochastic Volatility Models with Application to Inflation Forecast. **Journal of Econometrics**, nº 176(2), p. 162-172, 2013.

CHAN, M. *Modelos de previsão de inflação e estudo da dinâmica inflacionária brasileira*. 2009. 54 f. Dissertação (Mestrado em Finanças e Economia Empresarial), Escola de Pós-graduação em Economia, Fundação Getúlio Vargas, 2009.

CHARNES A., COOPER W. W. Management Models and Industrial Applications of Linear Programming, John Wiley & Sons, New York. 1961.

CHAUVET, M. Leading indicators of inflation for Brazil. **Pesquisa e Planejamento Econômico**, 31(1), p. 43–74. 2001. Disponível em: <http://ppe.ipea.gov.br/index.php/ppe/article/view/160/95> Acesso em: 28 jan. 2018.

CHERNAVSKY, E. Um Estudo do Desempenho das previsões do Relatório FOCUS/BCB. Texto para discussão. São Paulo: Faculdade de Economia e Administração, Universidade de São Paulo, 2011.

CLARK, T.E., MCCRACKEN, M.W. Forecast-Based Model Selection in the Presence of Structural Breaks. Federal Reserve Bank of Kansas City, **Research Working Paper** v. 02-05,2002.

CLEMENTS, M.; HENDRY, D. **Forecasting Economic Time Series**. Cambridge University Press, 1998.

CORRÊA, J. M.; NETO, A. C.; JÚNIOR, L. A. T.; CARREÑO, E. M.; FARIA, A. E. Combinação linear de previsões com ajuste numérico com programação não linear MINIMAX. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 11, nº 1, p. 79-95, Jan/Mar., 2016.

CUSBERT, T.; KENDALL, E. Meet MARTIN, the RBA's New Macroeconomic Model. **Reserve Bank of Australia - Bulletin**, Mar., 2018. Disponível em:<https://www.rba.gov.au/publications/bulletin/2018/mar/pdf/meet-martin-the-rbas-new-macroeconomic-model.pdf> Acesso em: 28 jan. 2018.

DE LUCA, G.; CARFORA, A. Predicting U.S. recessions through a combination of probability forecasts. **Empirical Economics**, v. 46, p. 127-144, 2014.

DE MENDONÇA, H. INHUDES, A. Transparência do banco central: Uma análise para o caso brasileiro. **Revista de Economia Política**, nº30(1), p.159-77, 2010.

DIEBOLD, F. X.; LOPEZ, J. A. Forecast Evaluation and Combination. **National Bureau of Economic Research** Working Paper Series no. 192, 1996.

ENGLE, R. F.; GRANGER, C. W. J. Co-integration and error-correction: representation, estimation and testing. **Econometrica**, 37, p. 424-438, 1987.

ENGLE, R. F.; YOO, S. Forecasting and testing in co-integrated system. **Journal of Econometrics**, v. 35, p. 143-159, 1987.

ERTUĞRUL, Irfan; GUNES, Mustafa. Fuzzy Goal Programming and an Application of Production Process. **Anal. And Des. Of Intel. Sys. Using Sc Tech**., ASC 41, p. 649-659. 2007.

FANG, Y. Forecasting Combination and Encompassing Tests. **International Journal of Forecasting**, 19, p. 87-94, 2003.

FARIA, A. E.; MUBWANDARIKWA, E. Multimodality on the Geometric Combination of Bayesian Forecasting Models. **International Journal of Statistics and Management System**, v. 3, p. 1-25, 2008.

FERREIRA, D., e PALMA, A. Forecasting Inflation with the Phillips Curve: A Dynamic Model Averaging Approach for Brazil.**Revista Brasileira de Economia.** vol.69, n.4, pp.451-465. 2015. Disponível em:<http://dx.doi.org/10.5935/0034-7140.20150021> Acesso em: 28 jan. 2018.

FERREIRA, R. T., BIERENS, H. e CASTELAR, I. Forecasting quarterly Brazilian GDP growth rate with linear and nonlinear diffusion index models. **EconomiA (revista da ANPEC)**, 6(3), p. 261–292. 2005. Disponível em:<http://www.anpec.org.br/revista/vol6/vol6n3p261_292.pdf> Acesso em: 28 jan. 2018.

FISHER, J.D.M., LIU, C.T., ZHOU, R. When Can We Forecast Inflation? Federal Reserve Bank of Chicago, **Economic Perspectives**, p. 30-42, 2002.

FLAVELL, R.B. A new goal programming formulation, **Omega4**, p. 731–732. 1976.

FRAGA, A. N. Dez Anos de Metas para a Inflação. In: BANCO CENTRAL DO BRASIL (Org.) In: D*ez anos de metas para a inflação no Brasil* 1999 – 2009. Brasília: Banco Central do Brasil, p. 351-399, 2011.

FRIEDMAN, M. The Role of Monetary Policy. **American Economic Review**, 58(1), p. 1-17, Mar., 1968.

GOMES, L. F. A. M.; MARANHÃO, F. J. C. A exploração de gás natural em Mexilhão: análise multicritério pelo método Todim. **Pesqui. Oper**., Rio de Janeiro , v. 28, n. 3, p. 491-509, Dec. 2008 . Disponível em: <http://dx.doi.org/10.1590/S0101-74382008000300006>. Acesso em: 28 jan. 2018.

GORDON, R. J. Price Inertia and Policy Ineffectiveness in the United States, 1890-1980, **Journal of Political Economy**, 90, p. 1087-1117. Dez., 1982.

HALL, J.; JÄÄSKELÄ, J. P. Inflation volatility and forecast accuracy. **Australian Economic Review**, v. 44, n. 4, p. 404-417, 2011.

HARVEY, D.; LEYBOURNE, S.; NEWBOLD, P. Testing the equality of prediction mean squared errors. **International Journal of forecasting**, v. 13, n. 2, p. 281-291, 1997.

HOLLAUER, G. BAHIA, L. D. ISSLER, J. V. Modelos Vetoriais de Correção de Erros Aplicados à Previsão de Crescimento da Produção Industrial. Brasília: IPEA, Texto para Discussão, n. 1172, Mar. 2006.

JADITZ, T., SAYERS, C. Predicting Inflation. **Bureau of Labor Statistics**, 1994

JONES, D. MEHRDAD, T. **Practical Goal Programming.** International Series in Operations Research and Management Science. Springer, 2010.

JORDAN, T. J; SAVIOZ, M. R. Does it Make Sense to Combine Forecasts from VAR Models? An Empirical Analysis with Inflation Forecasts for Switzerland. **Swiss National Bank – Quartely Bulletin**,Abr., 2003. Disponível em:<https://www.snb.ch/en/mmr/reference/quartbul_2003_4/source/quartbul_2003_4.en.pdf> Acesso em: 28 jan. 2018.

LEE, A. KANG, H. CHANG H. C. Fuzzy multiple goal programming applied to TFT-LCD supplier selection by downstream manufacturers. **Expert Systems With Applications**, 2008. DOI:10.1016/j.eswa.2008.08.044. Disponível em: < https://doi.org/10.1016/j.eswa.2008.08.044>. Acesso em: 28 jan. 2018.

LIMA, E. C. R.; CÉSPEDES, B. J. V. O desempenho do mercado (Focus) e do Bacen na previsão da inflação: Comparações com modelos lineares univariados. In: DE PAULA, L. F. R.; FERREIRA, L. R.; ASSIS, M. (Org.). *Perspectivas para a economia brasileira: Inserção internacional e políticas públicas*. Rio de Janeiro: EDUERJ, 2006.

LIMA, E.C.R.; ALVES, P. *O Desempenho do mercado (Focus) na previsão da inflação:* Novos resultados? Brasília: IPEA, Texto para Discussão, n. 1621, Jun. 2011.

LIMA, E.J.A.L; ARAÚJO, F; SILVA.J.R.C. Previsão e Modelos Macroeconômicos no Banco Central do Brasil In: BANCO CENTRAL DO BRASIL (Org.) D*ez anos de metas para a inflação no Brasil* 1999 – 2009. Brasília: Banco Central do Brasil, p. 351-399, 2011.

LIN J. L.; TSAY, R. Co-integration constraint and forecasting: an empirical examination. **Journal of Applied Econometrics**, v. 11, p. 519-538, 1996.

MEHRA, Y. P. The Forecast Performance of Alternative Models of Inflation, FRB **Richmond Economic Review**, vol. 74, no. 5, pp. 10-18. Set/Out., 1988.

MELTZER, A. H. Origins of the Great Inflation. **Federal Reserve Bank of St. Louis Review**, v. 87, n. Mar/Abr. 2005. Disponível em:<https://files.stlouisfed.org/research/publications/review/05/03/part2/Meltzer.pdf> Acesso em: 28 jan. 2018.

MINELLA, A.; SOUZA-SOBRINHO, N. F. Previsão e Modelos Macroeconômicos no Banco Central do Brasil In: BANCO CENTRAL DO BRASIL (Org.) D*ez anos de metas para a inflação no Brasil* 1999 – 2009. Brasília: Banco Central do Brasil, p. 35-93, 2011.

MIRRAZAVI, S. K; JONES, D. F.; TAMIZ, M..A comparison of genetic and conventional methods for the solution of integer goal programmes. **European Journal Of Operational Research**, v.132, n.3, p. 594-602. Ago. 2001.

MORAIS NETO, G. C. de. *Sistema Decisório Interativo de Alocação de Fluxo de Cargas*. 1988. 154 f. Dissertação (Mestrado em Sistemas e Computação) - Instituto Militar de Engenharia, Rio de Janeiro, 1988.

NEWBOLD, P.; GRANGER, C. W. J. Experience with Forecasting Univariate Times Series and the Combination of Forecasts. **Journal of the Royal Statistical Society**. v. 137, p. 131-165, 1974.

ORPHANIDES, A., VAN NORDEN, S. The Reliability of Inflation Forecast Based on Output Gap Estimates in Real Time. **Journal of Money, Credit, and Banking**, v. 37, p. 583-600, 2004.

PHELPS, E. S. Money-Wage Dynamics and Labor-Market Equilibrium. **Journal of Political Economy** 76 (4): p. 678-711, 1968.

PHELPS, E. S. Phillips Curves, Expectations of Inflation and Optimal Unemployment over Time. **Economica** 34 (135): p. 254-281, 1967.

PHILLIPS, A. W. The Relation between Unemployment and the Rate of Change of Money Wage Rates in the United Kingdom, 1861-1957. **Economica** 25 (100): p. 283-299, 1958.

PIMENTA JR., T. HIGUCHI, R. H. Variáveis Macroeconômicas e o Ibovespa: Um Estudo da Relação de Causalidade, **REAd - Revista Eletrônica de Administração, Ed.** 60, v. 14, n. 2, Mai-Ago, 2008.

PORTUGAL, M. Política Fiscal na primeira fase do Plano Real, 1993-1997. In: BACHA, E. (org.) *A crise fiscal e monetária brasileira: ensaios em homenagem a Fabio de Oliveira Barbosa*. 1a ed. Rio de Janeiro: Civilização Brasileira, p.373-399,2016.

RAGSDALE, C. **Spreadsheet Modeling & Decision Analysis:**A Practical Introduction to Management Science. 6 ed. South-Western, 2010.

RBA - RESERVE BANK OF AUSTRALIA (Austrália). Monetary Policy and the Exchange Rate: Evaluation of VAR Models. Jul., 2010.

SIMS, C. A. Macroeconomics and reality. **Econometrica** 48, p.1-48. 1980.

SIMS, C.A. The role of models and probabilities in the monetary policy process. **Brookings Papers on Economic Activity**, v. 2, p. 1–40, 2002.

SNB - SWISS NATIONAL BANK ECONOMIC STUDIES (Suíça). *Forecasting Swiss inflation using VAR models*. Zurique. Fev., 2006.

STOCK, J. H.; WATSON, M. Combination forecasts of output growth in a seven-country data set. **Journal of Forecasting**, v. 23, p. 105-430, 2004.

STOCK, J.H., AND M.W. WATSON, Forecasting output and inflation: The role of asset prices, **Journal of Economic Literature,** 41: p. 788-829, 2003.

STOCK, J.H., WATSON, M.W. Forecasting Inflation. **Journal of Monetary Economics,** v.44, p. 293-335, Oct.,1999.

STOCK, J.H., WATSON, M.W. Why Has U.S. Inflation Become Harder to Forecast? **Journal of Money, Credit, and Banking,** v. 39, p. 3-34, 2007.

STOCK, J.H.; WATSON, M.W. Phillips curve inflation forecasts.Federal Reserve Bank of Boston,**National Bureau of Economic Research**, Conference Series; [Proceedings], vol. 53. 2008.

STOCKTON, D. J., GLASSMAN, J.E. An Evaluation of the Forecast Performance of Alternative Models of Inflation. **The Review of Economics and Statistics**, v. 69, p. 108-117, 1987.

THOMA, M.A.; GRAY, J.A. On leading indicators: Getting it straight. Federal Reserve Bank of Dallas, **Texas conference on monetary economics Paper** No. 4, 1994.

WINKLER, R. L.; MAKRIDAKIS, S. The combination of Forecasting. **Journal of the Royal Statistical Society**, v. 146, p. 150-157, 1983.

ANEXO A –Anexo Estatístico

Gráfico 2 – Séries temporais das variáveis explicativas e explicadas em primeiras diferenças

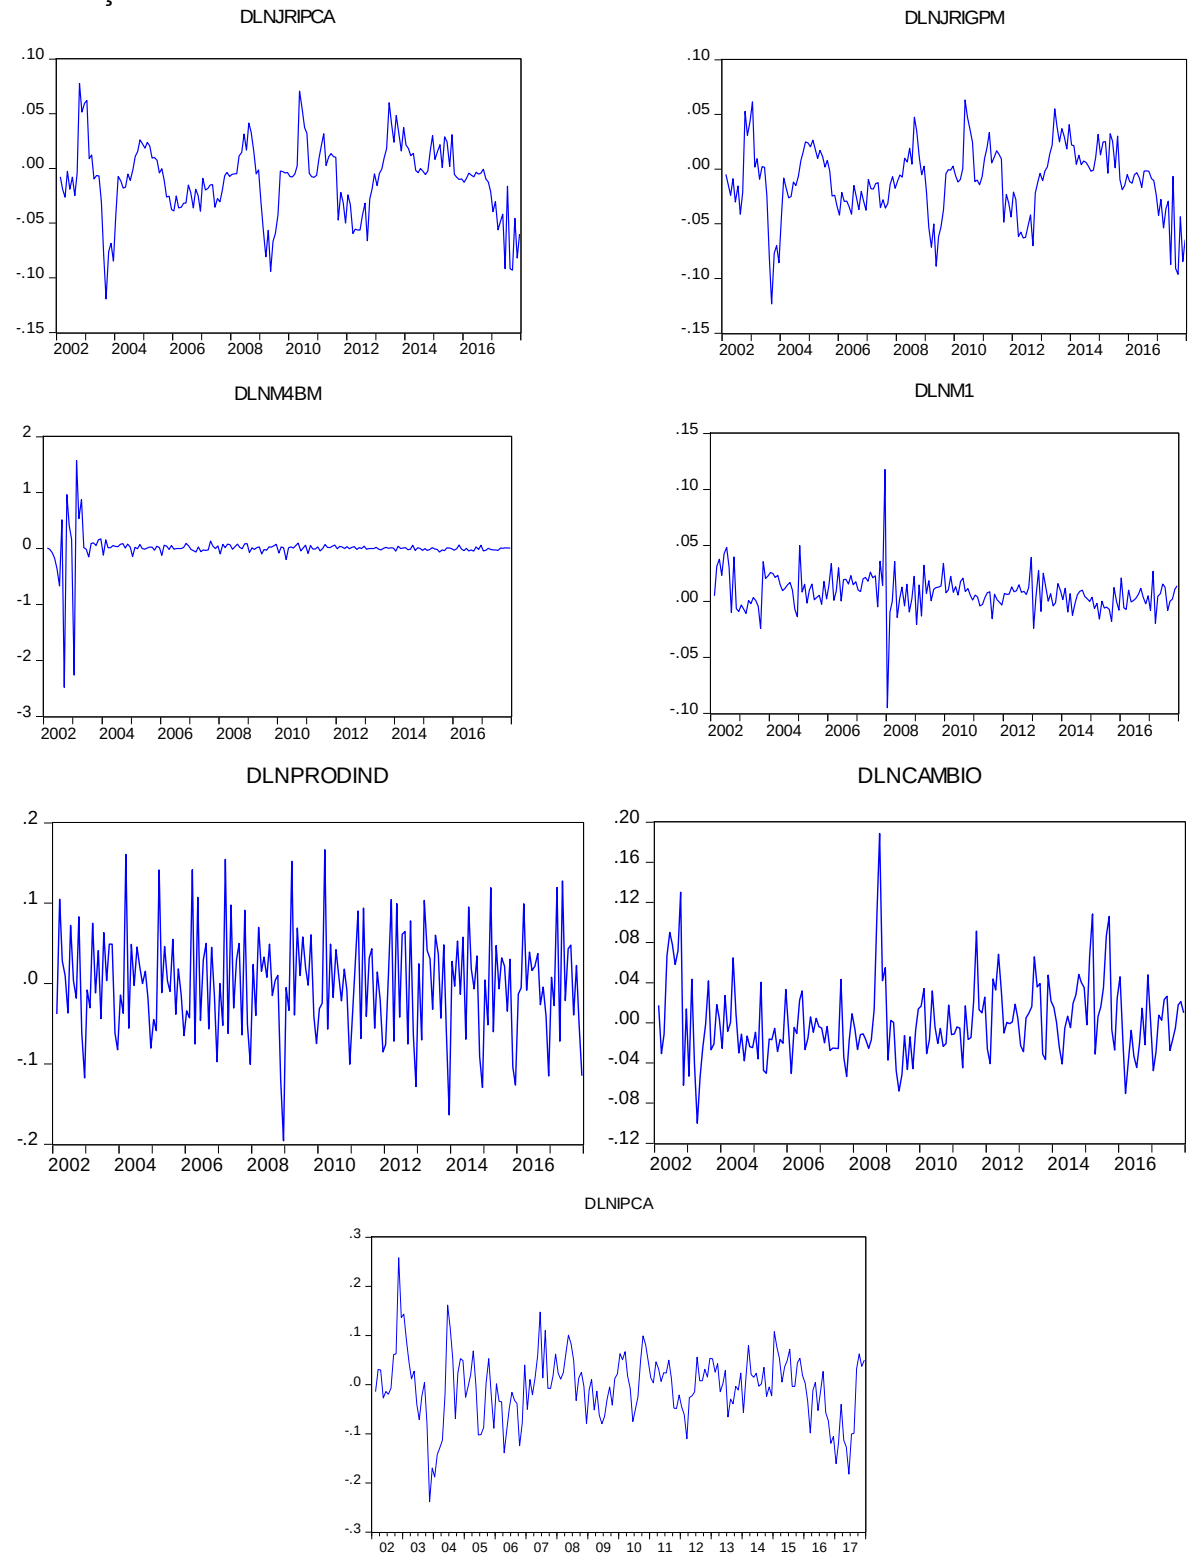

Fonte: O autor, 2019.

Tabela 4 - Resultados dos testes do traço e máximo autovalor (cointegração)
(continua)

			Teste do Traço			
Modelo	Lag	No. de CE(s)[a]	Autovalor	Traço	Valor Crítico 5%	Prob.
VAR I	1	Nenhuma *	0.243307	106.0152	29.79707	0
		Pelo menos 1 *	0.19907	53.32242	15.49471	0
		Pelo menos 2 *	0.058375	11.36793	3.841466	0.0007
VAR I	2	Nenhuma *	0.207097	86.72389	29.79707	0
		Pelo menos 1 *	0.15838	43.09774	15.49471	0
		Pelo menos 2 *	0.055232	10.68144	3.841466	0.0011
VAR I	3	Nenhuma *	0.189033	89.54519	29.79707	0
		Pelo menos 1 *	0.168821	50.36345	15.49471	0
		Pelo menos 2 *	0.080948	15.78517	3.841466	0.0001
VAR II	1	Nenhuma *	0.484286	232.1292	47.85613	0.0001
		Pelo menos 1 *	0.252115	106.9727	29.79707	0
		Pelo menos 2 *	0.198032	52.06702	15.49471	0
		Pelo menos 3 *	0.053326	10.35734	3.841466	0.0013
VAR II	2	Nenhuma *	0.455591	199.1131	47.85613	0
		Pelo menos 1 *	0.194614	84.79882	29.79707	0
		Pelo menos 2 *	0.162405	44.10929	15.49471	0
		Pelo menos 3 *	0.055786	10.79171	3.841466	0.001
VAR II	3	Nenhuma *	0.259907	153.2893	47.85613	0
		Pelo menos 1 *	0.192059	97.00606	29.79707	0
		Pelo menos 2 *	0.182423	57.12535	15.49471	0
		Pelo menos 3 *	0.098841	19.46174	3.841466	0
VAR III	1	Nenhuma *	0.298134	119.9635	29.79707	0
		Pelo menos 1 *	0.198	53.05516	15.49471	0
		Pelo menos 2 *	0.0583	11.35285	3.841466	0.0008
VAR III	2	Nenhuma *	0.288029	109.0644	29.79707	0
		Pelo menos 1 *	0.169642	45.19746	15.49471	0
		Pelo menos 2 *	0.053054	10.24853	3.841466	0.0014
VAR III	3	Nenhuma *	0.326816	125.3961	29.79707	0
		Pelo menos 1 *	0.175182	51.39329	15.49471	0
		Pelo menos 2 *	0.078947	15.37846	3.841466	0.0001
VAR IV	1	Nenhuma *	0.325583	127.7313	29.79707	0
		Pelo menos 1 *	0.195292	53.28306	15.49471	0
		Pelo menos 2 *	0.0626	12.21797	3.841466	0.0005
VAR IV	2	Nenhuma *	0.268006	108.8232	29.79707	0
		Pelo menos 1 *	0.178103	50.17041	15.49471	0
		Pelo menos 2 *	0.068281	13.29604	3.841466	0.0003

Tabela 4 - Resultados dos testes do traço e máximo autovalor (cointegração) (continuação)

Modelo	Lag	No. de CE(s)[a]	Autovalor	Traço	Valor Crítico 5%	Prob.
VAR IV	3	Nenhuma *	0.195793	93.42601	29.79707	0
		Pelo menos 1 *	0.162658	52.67906	15.49471	0
		Pelo menos 2 *	0.09894	19.48227	3.841466	0

Teste do máximo autovalor

Modelo	Lag	No. de CE(s)[a]	Autovalor	Máximo Autovalor	Valor Crítico 5%	Prob.
VAR I	1	Nenhuma *	0.243307	52.69277	21.13162	0
		Pelo menos 1 *	0.19907	41.95449	14.2646	0
		Pelo menos 2 *	0.058375	11.36793	3.841466	0.0007
VAR I	2	Nenhuma *	0.207097	43.62614	21.13162	0
		Pelo menos 1 *	0.15838	32.4163	14.2646	0
		Pelo menos 2 *	0.055232	10.68144	3.841466	0.0011
VAR I	3	Nenhuma *	0.189033	39.18174	21.13162	0.0001
		Pelo menos 1 *	0.168821	34.57828	14.2646	0
		Pelo menos 2 *	0.080948	15.78517	3.841466	0.0001
VAR II	1	Nenhuma *	0.484286	125.1565	27.58434	0
		Pelo menos 1 *	0.252115	54.90569	21.13162	0
		Pelo menos 2 *	0.198032	41.70967	14.2646	0
		Pelo menos 3 *	0.053326	10.35734	3.841466	0.0013
VAR II	2	Nenhuma *	0.455591	114.3142	27.58434	0
		Pelo menos 1 *	0.194614	40.68953	21.13162	0
		Pelo menos 2 *	0.162405	33.31757	14.2646	0
		Pelo menos 3 *	0.055786	10.79171	3.841466	0.001
VAR II	3	Nenhuma *	0.259907	56.28319	27.58434	0
		Pelo menos 1 *	0.192059	39.88071	21.13162	0.0001
		Pelo menos 2 *	0.182423	37.66361	14.2646	0
		Pelo menos 3 *	0.098841	19.46174	3.841466	0
VAR III	1	Nenhuma *	0.298134	66.90835	21.13162	0
		Pelo menos 1 *	0.198	41.7023	14.2646	0
		Pelo menos 2 *	0.0583	11.35285	3.841466	0.0008
VAR III	2	Nenhuma *	0.288029	63.86697	21.13162	0
		Pelo menos 1 *	0.169642	34.94893	14.2646	0
		Pelo menos 2 *	0.053054	10.24853	3.841466	0.0014
VAR III	3	Nenhuma *	0.326816	74.00285	21.13162	0
		Pelo menos 1 *	0.175182	36.01483	14.2646	0
		Pelo menos 2 *	0.078947	15.37846	3.841466	0.0001
VAR IV	1	Nenhuma *	0.325583	74.44826	21.13162	0
		Pelo menos 1 *	0.195292	41.0651	14.2646	0
		Pelo menos 2 *	0.0626	12.21797	3.841466	0.0005

Tabela 4 - Resultados dos testes do traço e máximo autovalor (cointegração) (conclusão)

Modelo	Lag	No. de CE(s)[a]	Autovalor	Máximo Autovalor	Valor Crítico 5%	Prob.
VAR IV	2	Nenhuma *	0.268006	58.65283	21.13162	0
		Pelo menos 1 *	0.178103	36.87437	14.2646	0
		Pelo menos 2 *	0.068281	13.29604	3.841466	0.0003
VAR IV	3	Nenhuma *	0.195793	40.74695	21.13162	0
		Pelo menos 1 *	0.162658	33.19679	14.2646	0
		Pelo menos 2 *	0.09894	19.48227	3.841466	0

Nota: * denota rejeição da hipótese nula no nível 0,05.[a] número de cointegrações da hipótese nula (H_0).A ordenação das variáveis é: VAR I – DLNIPCA, DLNJREALIGPM, DLNCAMBIO; VAR II – DLNIPCA, DLNJREALIPCA, DLNM4BMA, DLNCAMBIO; VAR III – DLNIPCA, DLNJREALIGPM, DLNPRODIND; e VAR IV – DLNIPCA, DLNJREALIGPM, DLNM1.
Fonte: O autor, 2019.

Tabela 5- Resultados dos testes de seleção de ordem de defasagens no período amostral de 2002M01 até 2016M12

(continua)

Modelo	Lag	LogL	LR	FPE	AIC	SC	HQ
VAR I	0	897.751	NA	0.000	-10.716	-10.660	-10.693
	1	1041.597	280.801	**0.000***	**-12.331***	**-12.106***	**-12.240***
	2	1043.903	4.418	0.000	-12.250	-11.858	-12.091
	3	1045.282	2.593	0.000	-12.159	-11.599	-11.932
	4	1056.273	20.271	0.000	-12.183	-11.455	-11.887
	5	1060.966	8.487	0.000	-12.131	-11.235	-11.768
	6	1071.247	18.222	0.000	-12.147	-11.082	-11.715
	7	1086.483	26.458	0.000	-12.221	-10.989	-11.721
	8	1091.031	7.734	0.000	-12.168	-10.768	-11.600
	9	1096.924	9.810	0.000	-12.131	-10.562	-11.494
	10	1101.708	7.792	0.000	-12.080	-10.344	-11.376
	11	1109.395	12.243	0.000	-12.065	-10.160	-11.292
	12	1126.614	**26.809***	0.000	-12.163	-10.091	-11.322
VAR II	0	976.007	NA	0.000	-11.641	-11.566	-11.610
	1	1148.406	334.475	0.000	-13.514	**-13.140***	**-13.362***
	2	1155.260	12.970	0.000	-13.404	-12.732	-13.132
	3	1172.448	31.700	0.000	-13.419	-12.448	-13.024
	4	1189.824	31.213	0.000	-13.435	-12.165	-12.920
	5	1208.554	32.749	0.000	-13.468	-11.899	-12.831
	6	1228.015	33.096	0.000	-13.509	-11.642	-12.751
	7	1260.447	53.601	0.000	-13.706	-11.540	-12.827
	8	1283.212	36.533	0.000	-13.787	-11.322	-12.787
	9	1296.009	19.924	0.000	-13.749	-10.985	-12.627
	10	1308.933	19.501	0.000	-13.712	-10.650	-12.469
	11	1329.933	30.682	0.000	-13.772	-10.411	-12.408
	12	1356.848	**38.037***	**0.000***	**-13.902***	-10.243	-12.417
VAR III	0	805.237	NA	0.000	-9.608	-9.552	-9.585
	1	936.384	256.012	0.000	-11.070	**-10.846***	-10.980
	2	941.149	9.130	0.000	-11.020	-10.628	-10.861
	3	945.121	7.469	0.000	-10.960	-10.399	-10.732
	4	963.480	33.860	0.000	-11.072	-10.343	-10.776
	5	965.812	4.217	0.000	-10.992	-10.096	-10.628
	6	982.372	29.352	0.000	-11.082	-10.018	-10.650
	7	1000.967	32.291	0.000	-11.197	-9.965	-10.697
	8	1010.814	16.745	0.000	-11.207	-9.807	-10.639
	9	1032.726	36.477	0.000	-11.362	-9.794	-10.725
	10	1043.681	17.842	0.000	-11.385	-9.649	-10.681
	11	1069.142	40.555	0.000	-11.583	-9.678	-10.810
	12	1135.518	**103.339***	**0.000***	**-12.270***	-10.197	**-11.429***

.

Tabela 5- Resultados dos testes de seleção de ordem de defasagens no período amostral de 2002M01 até 2016M12
(conclusão)

Modelo	Lag	LogL	LR	FPE	AIC	SC	HQ
VAR IV	0	1028.477	NA	0.000	-12.281	-12.225	-12.258
	1	1164.362	265.260	**0.000***	-13.801	**-13.577***	**-13.710***
	2	1169.453	9.756	0.000	-13.754	-13.362	-13.595
	3	1172.679	6.065	0.000	-13.685	-13.125	-13.457
	4	1185.125	22.955	0.000	-13.726	-12.998	-13.431
	5	1190.940	10.516	0.000	-13.688	-12.792	-13.324
	6	1202.863	21.132	0.000	-13.723	-12.659	-13.291
	7	1216.789	24.183	0.000	-13.782	-12.550	-13.282
	8	1223.857	12.019	0.000	-13.759	-12.358	-13.190
	9	1231.723	13.095	0.000	-13.745	-12.177	-13.109
	10	1235.608	6.327	0.000	-13.684	-11.948	-12.979
	11	1246.011	16.569	0.000	-13.701	-11.796	-12.928
	12	1264.350	**28.552***	0.000	**-13.813***	-11.740	-12.971

Nota: * indica a ordem de defasagem (*lag*) selecionada por cada critério.
Fonte: O autor, 2019.

Gráfico 5 – Funções de resposta ao impulso (FRI) dos modelos VAR com 2 defasagem

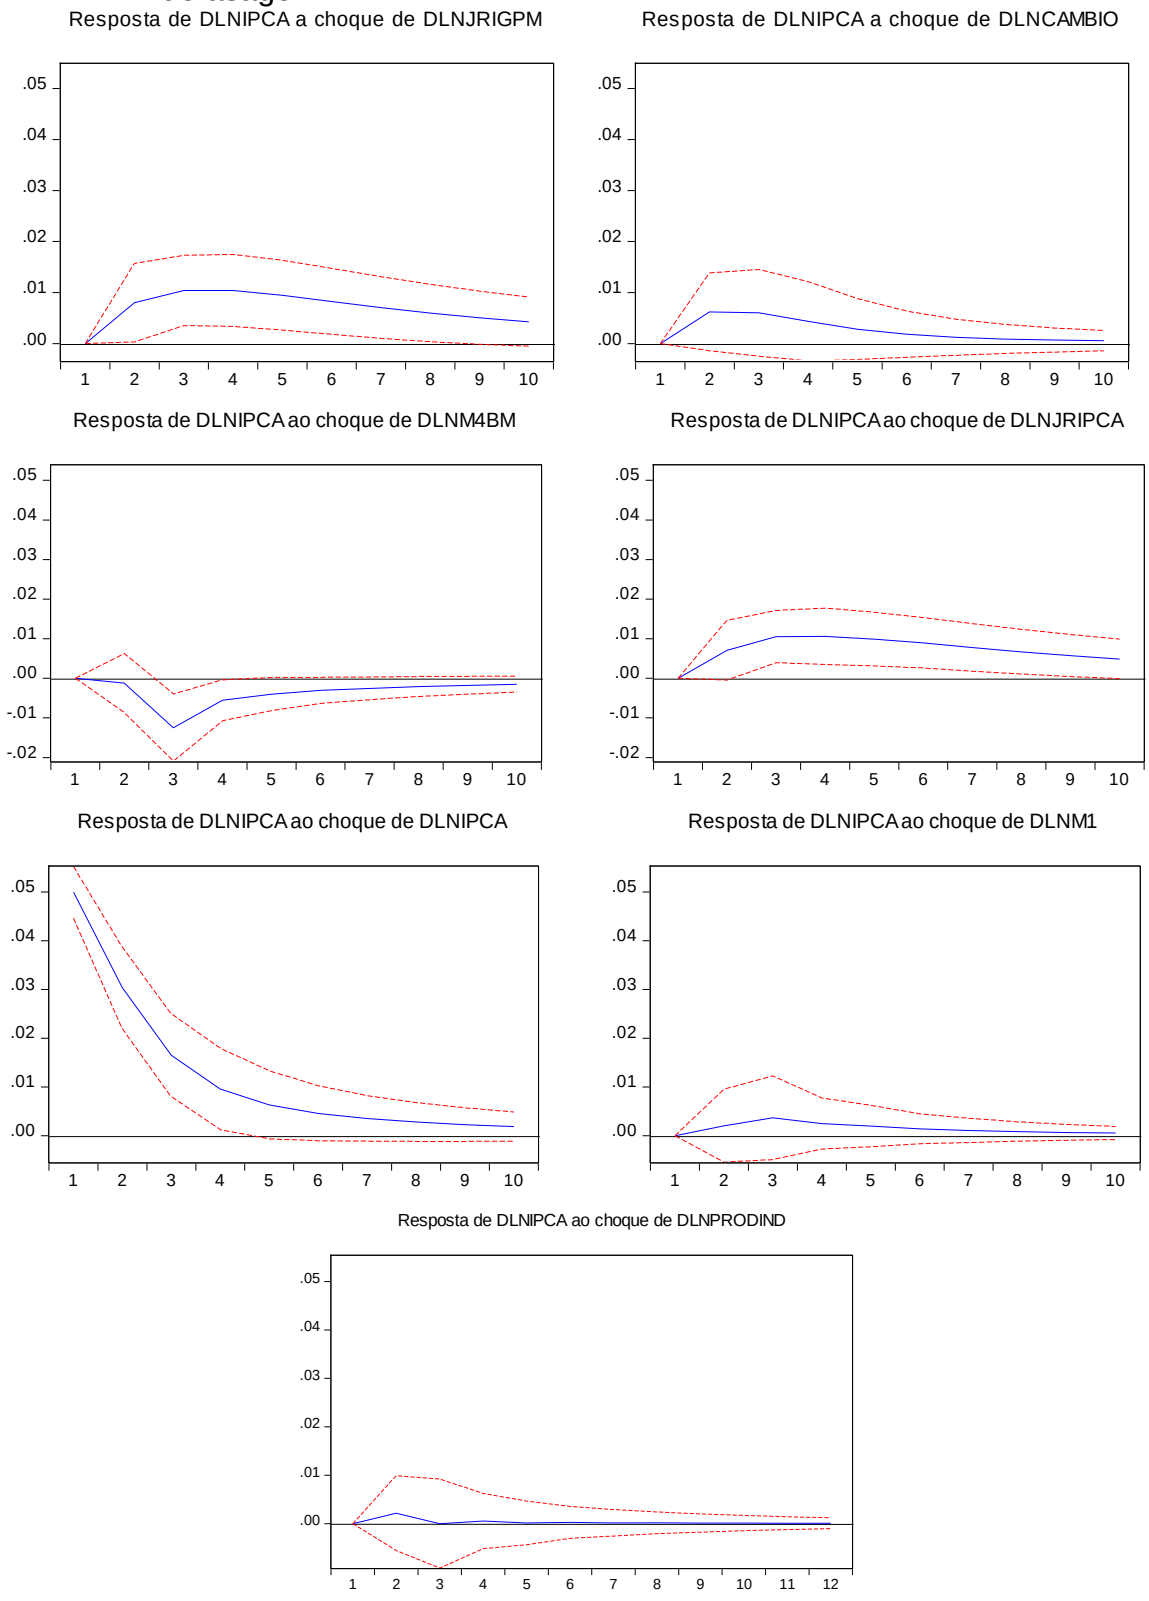

Fonte: O autor, 2019.

Gráfico 6 – Funções de resposta ao impulso (FRI) dos modelos VAR com 3 defasagem

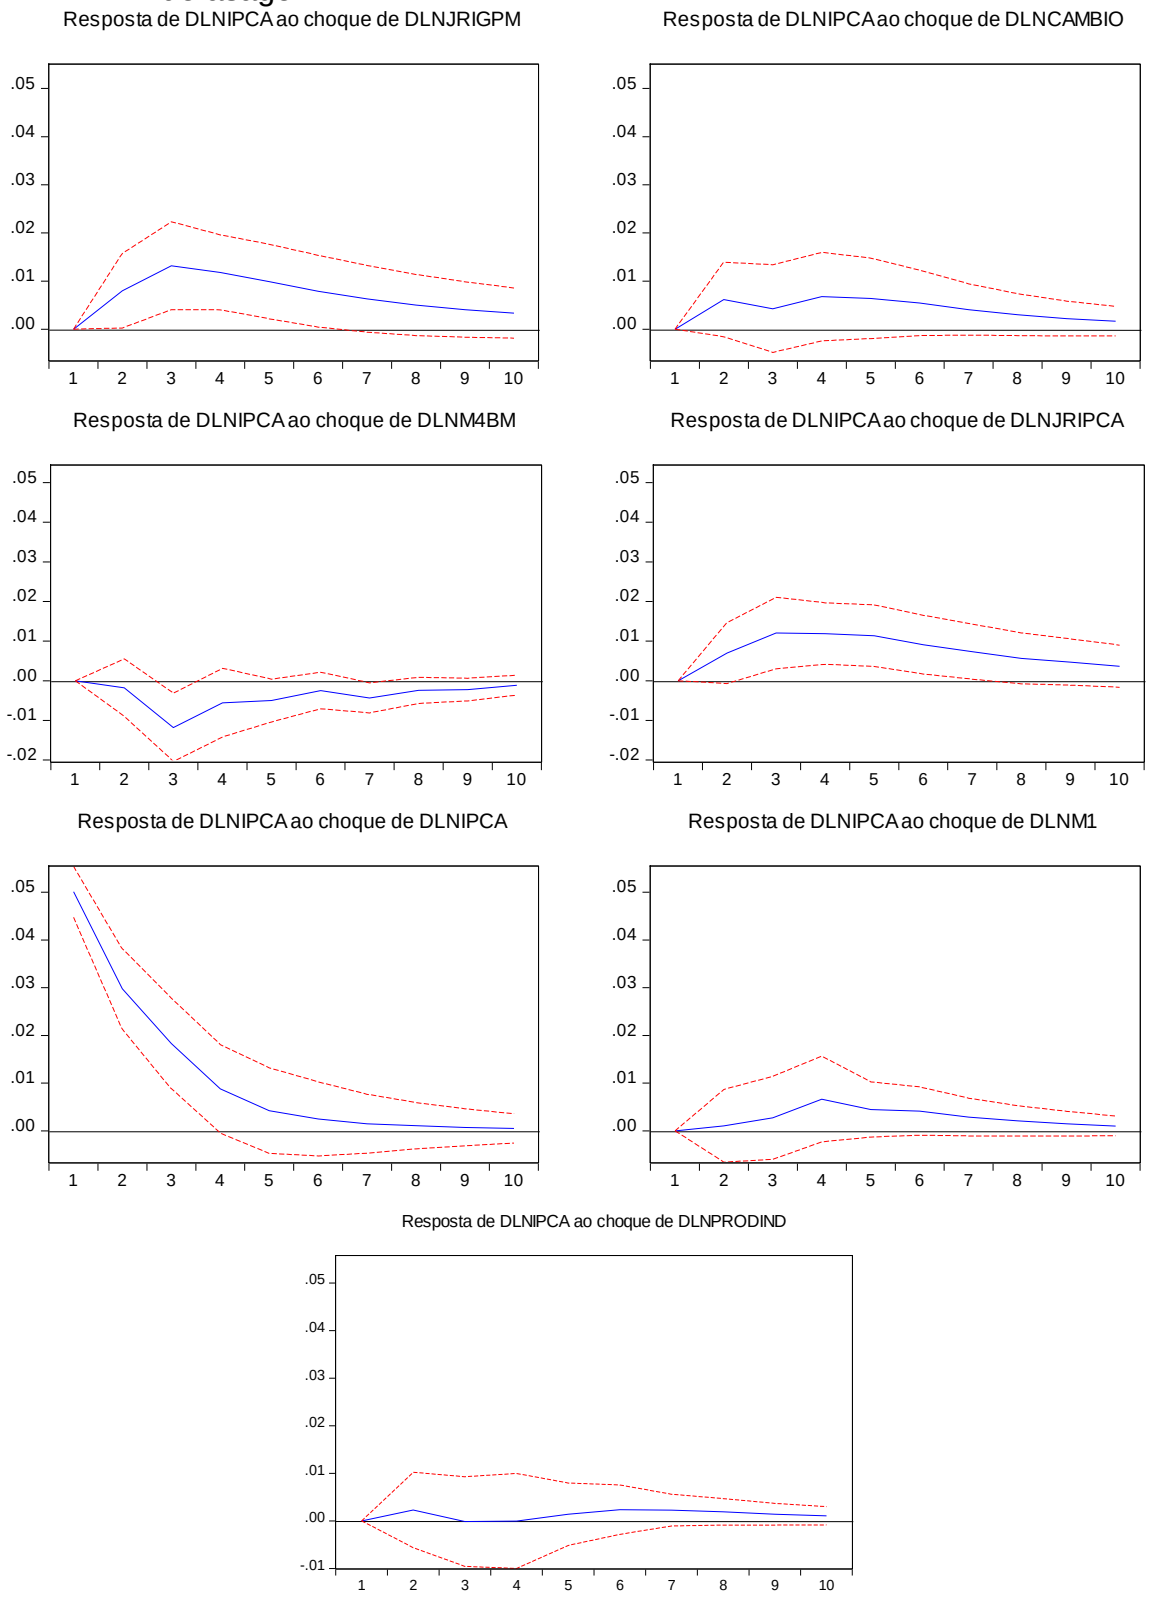

Fonte: O autor, 2019.

Quadro 7- Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 12 passos à frente.

VAR I – LAG 1-1

Sample (adjusted): 2002M03 2016M12
Included observations: 178 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.585676	0.052931	-0.024856
	(0.06034)	(0.02237)	(0.04543)
	[9.70631]***	[2.36652]**	[-0.54710]
DLNJRIGPM(-1)	0.368794	0.760938	0.129017
	(0.12979)	(0.04811)	(0.09773)
	[2.84140]***	[15.8162]***	[1.32017]
DLNCAMBIO(-1)	0.173007	-0.027259	0.380364
	(0.09268)	(0.03435)	(0.06978)
	[1.86670]*	[-0.79347]	[5.45058]***
C	0.001906	-0.001940	0.002125
	(0.00384)	(0.00142)	(0.00289)
	[0.49656]	[-1.36394]	[0.73543]
R-squared	0.444175	0.644453	0.160295
Adj. R-squared	0.434592	0.638323	0.145817
Sum sq. resids	0.421375	0.057897	0.238892
S.E. equation	0.049211	0.018241	0.037053
F-statistic	46.34947	105.1288	11.07186
Log likelihood	285.5244	462.1764	336.0327
Akaike AIC	-3.163196	-5.148049	-3.730705
Schwarz SC	-3.091695	-5.076548	-3.659204
Mean dependent	-0.001000	-0.008108	0.001833
S.D. dependent	0.065445	0.030331	0.040091

VAR I – LAG 1-2

Sample (adjusted): 2002M04 2016M12
Included observations: 177 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.623499	0.040371	-0.009466
	(0.07711)	(0.02861)	(0.05804)
	[8.08547]***	[1.41128]	[-0.16309]
DLNIPCA(-2)	-0.061772	0.015353	-0.029526
	(0.07681)	(0.02849)	(0.05782)
	[-0.80418]	[0.53880]	[-0.51069]
DLNJRIGPM(-1)	0.429733	0.742616	0.141338
	(0.20646)	(0.07659)	(0.15540)
	[2.08143]**	[9.69618]***	[0.90952]
DLNJRIGPM(-2)	-0.050993	0.019696	0.000279
	(0.20803)	(0.07717)	(0.15658)
	[-0.24513]	[0.25523]	[0.00178]
DLNCAMBIO(-1)	0.167077	-0.038505	0.379600
	(0.10219)	(0.03791)	(0.07691)
	[1.63503]	[-1.01577]	[4.93543]***
DLNCAMBIO(-2)	0.010833	0.028389	0.004726
	(0.10323)	(0.03829)	(0.07770)
	[0.10494]	[0.74133]	[0.06083]
C	0.001804	-0.001923	0.002453
	(0.00391)	(0.00145)	(0.00294)
	[0.46112]	[-1.32539]	[0.83317]
R-squared	0.447509	0.646442	0.163941
Adj. R-squared	0.428009	0.633963	0.134433
Sum sq. resids	0.418283	0.057560	0.236968
S.E. equation	0.049603	0.018401	0.037335
F-statistic	22.94955	51.80429	5.555808
Log likelihood	284.0735	459.5978	334.3620
Akaike AIC	-3.130774	-5.114100	-3.699006
Schwarz SC	-3.005164	-4.988489	-3.573395

Mean dependent	-0.001180	-0.008074	0.002016
S.D. dependent	0.065587	0.030414	0.040130

VAR I – LAG 1-3

Sample (adjusted): 2002M05 2016M12
Included observations: 176 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.615163	0.040136	-0.007917
	(0.07754)	(0.02880)	(0.05882)
	[7.93299]***	[1.39348]	[-0.13459]
DLNIPCA(-2)	-0.013838	0.017719	-0.049924
	(0.09171)	(0.03406)	(0.06957)
	[-0.15089]	[0.52016]	[-0.71763]
DLNIPCA(-3)	-0.076042	-0.008912	0.032096
	(0.07728)	(0.02871)	(0.05863)
	[-0.98392]	[-0.31045]	[0.54748]
DLNJRIGPM(-1)	0.428993	0.736752	0.134352
	(0.20747)	(0.07706)	(0.15738)
	[2.06770]**	[9.56051]***	[0.85367]
DLNJRIGPM(-2)	0.111298	0.054041	0.021618
	(0.26140)	(0.09709)	(0.19829)
	[0.42578]	[0.55661]	[0.10902]
DLNJRIGPM(-3)	-0.163699	-0.029577	-0.034516
	(0.20865)	(0.07750)	(0.15828)
	[-0.78456]	[-0.38165]	[-0.21808]
DLNCAMBIO(-1)	0.164465	-0.041608	0.381321
	(0.10282)	(0.03819)	(0.07800)
	[1.59955]	[-1.08949]	[4.88904]***
DLNCAMBIO(-2)	-0.032329	0.009700	-0.012586
	(0.11184)	(0.04154)	(0.08484)
	[-0.28906]	[0.23350]	[-0.14836]
DLNCAMBIO(-3)	0.122148	0.053465	0.046301
	(0.10386)	(0.03858)	(0.07879)
	[1.17602]	[1.38587]	[0.58766]
C	0.001566	-0.001906	0.002221
	(0.00397)	(0.00147)	(0.00301)

VAR II – LAG 1-1

Sample (adjusted): 2002M03 2016M12
Included observations: 178 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.571849	-0.085092	0.047858	-0.030145
	(0.06098)	(0.36862)	(0.02232)	(0.04362)
	[9.37792]***	[-0.23084]	[2.14375]**	[-0.69115]
DLNM4BM(-1)	0.010570	-0.340490	-0.006021	-0.040516
	(0.01179)	(0.07129)	(0.00432)	(0.00844)
	[0.89630]	[-4.77625]***	[-1.39459]	[-4.80327]***
DLNJRIPCA(-1)	0.415741	0.431856	0.777019	0.089839
	(0.12835)	(0.77586)	(0.04699)	(0.09180)
	[3.23924]***	[0.55662]	[16.5366]***	[0.97861]
DLNCAMBIO(-1)	0.159060	-0.742033	-0.003207	0.370538
	(0.09265)	(0.56007)	(0.03392)	(0.06627)
	[1.71682]*	[-1.32490]	[-0.09455]	[5.59144]***
C	0.001914	0.009863	-0.001621	0.001907
	(0.00379)	(0.02290)	(0.00139)	(0.00271)
	[0.50526]	[0.43074]	[-1.16873]	[0.70392]
R-squared	0.453934	0.123806	0.675686	0.255530
Adj. R-squared	0.441308	0.103547	0.668187	0.238317
Sum sq. resids	0.413977	15.12800	0.055486	0.211798
S.E. equation	0.048918	0.295711	0.017909	0.034990
F-statistic	35.95287	6.111197	90.10838	14.84504
Log likelihood	287.1008	-33.16501	465.9616	346.7464
Akaike AIC	-3.169672	0.428820	-5.179344	-3.839848
Schwarz SC	-3.080296	0.518196	-5.089968	-3.750472
Mean dependent	-0.001000	0.004094	-0.007242	0.001833
S.D. dependent	0.065445	0.312323	0.031090	0.040091

	[0.39485]	[-1.29426]	[0.73844]
R-squared	0.457401	0.651800	0.166573
Adj. R-squared	0.427982	0.632922	0.121387
Sum sq. resids	0.410265	0.056600	0.236075
S.E. equation	0.049714	0.018465	0.037711
F-statistic	15.54830	34.52640	3.686388
Log likelihood	283.6732	457.9831	332.3066
Akaike AIC	-3.109923	-5.090717	-3.662575
Schwarz SC	-2.929782	-4.910575	-3.482434
Mean dependent	-0.001357	-0.007984	0.002091
S.D. dependent	0.065731	0.030477	0.040232

VAR II – LAG 1-2

Sample (adjusted): 2002M04 2016M12

Included observations: 177 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.615035	0.146340	0.046827	-0.037034
	(0.07639)	(0.46458)	(0.02847)	(0.05522)
	[8.05124]***	[0.31499]	[1.64497]	[-0.67066]
DLNIPCA(-2)	-0.080534	-0.442422	-0.003029	-0.007717
	(0.07571)	(0.46047)	(0.02821)	(0.05473)
	[-1.06365]	[-0.96080]	[-0.10736]	[-0.14100]
DLNM4BM(-1)	0.000539	-0.377196	-0.005800	-0.040528
	(0.01279)	(0.07777)	(0.00476)	(0.00924)
	[0.04215]	[-4.85043]***	[-1.21728]	[-4.38470]***
DLNM4BM(-2)	-0.030685	-0.137637	0.000545	0.003682
	(0.01352)	(0.08225)	(0.00504)	(0.00978)
	[-2.26888]**	[-1.67338]*	[0.10817]	[0.37660]
DLNJRIPCA(-1)	0.393542	0.762520	0.763282	-0.046632
	(0.20916)	(1.27206)	(0.07794)	(0.15120)
	[1.88151]*	[0.59944]	[9.79268]***	[-0.30842]
DLNJRIPCA(-2)	0.045212	-0.319620	0.020030	0.185865
	(0.21146)	(1.28603)	(0.07880)	(0.15286)
	[0.21381]	[-0.24853]	[0.25418]	[1.21594]
DLNCAMBIO(-1)	0.067638	-1.341607	-0.007360	0.391111
	(0.10736)	(0.65291)	(0.04001)	(0.07760)

VAR II – LAG 1-3

Sample (adjusted): 2002M05 2016M12

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.607653	-0.000846	0.043017	-0.040236
	(0.07871)	(0.44819)	(0.02927)	(0.05698)
	[7.72001]***	[-0.00189]	[1.46944]	[-0.70612]
DLNIPCA(-2)	-0.037947	-0.779066	0.005293	-0.007149
	(0.09197)	(0.52371)	(0.03421)	(0.06658)
	[-0.41259]	[-1.48758]	[0.15474]	[-0.10736]
DLNIPCA(-3)	-0.068864	0.811282	-0.009862	0.005067
	(0.07695)	(0.43815)	(0.02862)	(0.05570)
	[-0.89494]	[1.85160]*	[-0.34460]	[0.09096]
DLNM4BM(-1)	-0.001353	-0.378167	-0.006922	-0.041733
	(0.01311)	(0.07466)	(0.00488)	(0.00949)
	[-0.10318]	[-5.06518]***	[-1.41940]	[-4.39666]***
DLNM4BM(-2)	-0.029023	-0.252282	-0.000374	0.003512
	(0.01480)	(0.08430)	(0.00551)	(0.01072)
	[-1.96039]**	[-2.99263]***	[-0.06799]	[0.32764]
DLNM4BM(-3)	8.87E-05	-0.237683	-0.003875	-0.003561
	(0.01400)	(0.07972)	(0.00521)	(0.01014)
	[0.00633]	[-2.98132]***	[-0.74411]	[-0.35130]
DLNJRIPCA(-1)	0.384368	0.884744	0.756552	-0.052547
	(0.21150)	(1.20429)	(0.07866)	(0.15311)
	[1.81737]*	[0.73466]	[9.61797]***	[-0.34320]

	[0.63003]	[-2.05482]**	[-0.18397]	[5.03982]***
DLNCAMBIO(-2)	0.017601	0.597054	0.014712	-0.030282
	(0.10193)	(0.61990)	(0.03798)	(0.07368)
	[0.17268]	[0.96315]	[0.38733]	[-0.41099]
C	0.002195	0.010938	-0.001535	0.002470
	(0.00381)	(0.02315)	(0.00142)	(0.00275)
	[0.57655]	[0.47242]	[-1.08193]	[0.89738]
R-squared	0.474237	0.147274	0.676644	0.266166
Adj. R-squared	0.449200	0.106668	0.661247	0.231221
Sum sq. resids	0.398048	14.72257	0.055276	0.207994
S.E. equation	0.048676	0.296031	0.018139	0.035186
F-statistic	18.94193	3.626909	43.94398	7.616821
Log likelihood	288.4619	-31.07315	463.1822	345.9039
Akaike AIC	-3.157762	0.452804	-5.132003	-3.806823
Schwarz SC	-2.996262	0.614303	-4.970504	-3.645324
Mean dependent	-0.001180	0.004186	-0.007174	0.002016
S.D. dependent	0.065587	0.313207	0.031165	0.040130

DLNJRIPCA(-2)	0.147792	-1.886341	0.066610	0.261122
	(0.26967)	(1.53552)	(0.10029)	(0.19522)
	[0.54805]	[-1.22847]	[0.66414]	[1.33758]
DLNJRIPCA(-3)	-0.086509	1.427176	-0.049881	-0.096649
	(0.21456)	(1.22173)	(0.07980)	(0.15533)
	[-0.40320]	[1.16816]	[-0.62507]	[-0.62223]
DLNCAMBIO(-1)	0.073640	-1.412755	-0.006418	0.397679
	(0.10921)	(0.62183)	(0.04062)	(0.07906)
	[0.67432]	[-2.27193]**	[-0.15802]	[5.03028]***
DLNCAMBIO(-2)	-0.025400	0.732122	-0.012612	-0.073432
	(0.11804)	(0.67212)	(0.04390)	(0.08545)
	[-0.21519]	[1.08927]	[-0.28729]	[-0.85934]
DLNCAMBIO(-3)	0.096002	-1.705981	0.044435	0.082014
	(0.10354)	(0.58960)	(0.03851)	(0.07496)
	[0.92715]	[-2.89346]***	[1.15383]	[1.09412]
C	0.002055	0.015435	-0.001552	0.002198
	(0.00389)	(0.02212)	(0.00145)	(0.00281)
	[0.52904]	[0.69769]	[-1.07414]	[0.78152]
R-squared	0.480255	0.261723	0.681316	0.272910
Adj. R-squared	0.441992	0.207372	0.657854	0.219382
Sum sq. resids	0.392984	12.74184	0.054360	0.205954
S.E. equation	0.049101	0.279590	0.018262	0.035546
F-statistic	12.55129	4.815374	29.03981	5.098455
Log likelihood	287.4602	-18.68099	461.5368	344.3184
Akaike AIC	-3.118866	0.360011	-5.097009	-3.764982
Schwarz SC	-2.884683	0.594195	-4.862826	-3.530798
Mean dependent	-0.001357	0.004639	-0.007066	0.002091
S.D. dependent	0.065731	0.314042	0.031220	0.040232

VAR III – LAG 1-1

Sample (adjusted): 2002M03 2016M12

Included observations: 178 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.580229	0.010775	0.053497
	(0.06080)	(0.07824)	(0.02224)
	[9.54364]***	[0.13771]	[2.40577]**

VAR III – LAG 1-2

Sample (adjusted): 2002M04 2016M12

Included observations: 177 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.618871	0.011059	0.043663
	(0.07659)	(0.09735)	(0.02796)
	[8.08064]***	[0.11360]	[1.56168]

DLNPRODIND(-1)	0.035466	-0.198364	-0.031666
	(0.05819)	(0.07489)	(0.02128)
	[0.60948]	[-2.64885]***	[-1.48779]
DLNJRIGPM(-1)	0.395519	-0.148579	0.754365
	(0.13044)	(0.16786)	(0.04771)
	[3.03230]***	[-0.88514]	[15.8123]***
C	0.002412	-0.000410	-0.002013
	(0.00386)	(0.00497)	(0.00141)
	[0.62461]	[-0.08251]	[-1.42507]
R-squared	0.434252	0.042018	0.647649
Adj. R-squared	0.424498	0.025501	0.641573
Sum sq. resids	0.428898	0.710316	0.057377
S.E. equation	0.049648	0.063893	0.018159
F-statistic	44.51917	2.543921	106.6084
Log likelihood	283.9495	239.0497	462.9800
Akaike AIC	-3.145500	-2.641008	-5.157079
Schwarz SC	-3.073999	-2.569507	-5.085578
Mean dependent	-0.001000	0.000574	-0.008108
S.D. dependent	0.065445	0.064723	0.030331

DLNIPCA(-2)	-0.065315	0.000268	0.014075
	(0.07703)	(0.09791)	(0.02812)
	[-0.84793]	[0.00274]	[0.50053]
DLNPRODIND(-1)	0.037051	-0.164943	-0.026379
	(0.06004)	(0.07631)	(0.02192)
	[0.61714]	[-2.16144]**	[-1.20358]
DLNPRODIND(-2)	-0.001284	0.139118	0.027241
	(0.06045)	(0.07684)	(0.02207)
	[-0.02125]	[1.81045]*	[1.23432]
DLNJRIGPM(-1)	0.425716	-0.061622	0.750886
	(0.20930)	(0.26604)	(0.07641)
	[2.03397]**	[-0.23163]	[9.82722]***
DLNJRIGPM(-2)	-0.010192	-0.068568	0.008104
	(0.20908)	(0.26576)	(0.07633)
	[-0.04875]	[-0.25801]	[0.10618]
C	0.002375	-0.001023	-0.001973
	(0.00393)	(0.00500)	(0.00144)
	[0.60420]	[-0.20467]	[-1.37452]
R-squared	0.437989	0.059013	0.651691
Adj. R-squared	0.418154	0.025802	0.639398
Sum sq. resids	0.425490	0.687437	0.056706
S.E. equation	0.050029	0.063590	0.018264
F-statistic	22.08090	1.776901	53.01217
Log likelihood	282.5616	240.1056	460.9218
Akaike AIC	-3.113691	-2.633961	-5.129060
Schwarz SC	-2.988080	-2.508351	-5.003449
Mean dependent	-0.001180	-1.46E-05	-0.008074
S.D. dependent	0.065587	0.064427	0.030414

VAR III – LAG 1-3

Sample (adjusted): 2002M05 2016M12
Included observations: 176 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.612230	0.004253	0.043573
	(0.07737)	(0.09798)	(0.02790)
	[7.91275]***	[0.04340]	[1.56164]

VAR IV – LAG 1-1

Sample (adjusted): 2002M03 2016M12
Included observations: 178 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.583064	0.052771	-0.040810
	(0.06108)	(0.02246)	(0.02113)
	[9.54592]***	[2.34940]**	[-1.93168]*

DLNIPCA(-2)	-0.001210	0.021717	0.020132
	(0.09160)	(0.11599)	(0.03303)
	[-0.01321]	[0.18723]	[0.60948]
DLNIPCA(-3)	-0.092561	-0.041700	-0.010373
	(0.07774)	(0.09845)	(0.02804)
	[-1.19059]	[-0.42357]	[-0.36998]
DLNPRODIND(-1)	0.036468	-0.156420	-0.032492
	(0.06143)	(0.07778)	(0.02215)
	[0.59369]	[-2.01093]**	[-1.46683]
DLNPRODIND(-2)	-0.003638	0.123664	0.035564
	(0.06177)	(0.07823)	(0.02228)
	[-0.05888]	[1.58085]	[1.59643]
DLNPRODIND(-3)	-0.009214	-0.110317	0.052279
	(0.06172)	(0.07816)	(0.02226)
	[-0.14929]	[-1.41142]	[2.34877]**
DLNJRIGPM(-1)	0.439873	-0.016230	0.733525
	(0.21190)	(0.26834)	(0.07642)
	[2.07581]**	[-0.06048]	[9.59911]***
DLNJRIGPM(-2)	0.114482	-0.237130	0.059986
	(0.26689)	(0.33796)	(0.09624)
	[0.42895]	[-0.70164]	[0.62328]
DLNJRIGPM(-3)	-0.134790	0.161554	-0.027962
	(0.21058)	(0.26666)	(0.07594)
	[-0.64010]	[0.60584]	[-0.36822]
C	0.002406	-0.000831	-0.001940
	(0.00400)	(0.00506)	(0.00144)
	[0.60208]	[-0.16423]	[-1.34637]
R-squared	0.443368	0.075178	0.663291
Adj. R-squared	0.413190	0.025037	0.645035
Sum sq. resids	0.420875	0.674897	0.054732
S.E. equation	0.050353	0.063762	0.018158
F-statistic	14.69138	1.499331	36.33408
Log likelihood	281.4264	239.8706	460.9360
Akaike AIC	-3.084391	-2.612166	-5.124273
Schwarz SC	-2.904250	-2.432025	-4.944132
Mean dependent	-0.001357	-0.000174	-0.007984
S.D. dependent	0.065731	0.064576	0.030477

DLNJRIGPM(-1)	0.397853	0.755379	-0.106860
	(0.13073)	(0.04807)	(0.04522)
	[3.04332]***	[15.7126]***	[-2.36325]**
DLNM1(-1)	0.118558	-0.039636	-0.128823
	(0.21254)	(0.07816)	(0.07351)
	[0.55782]	[-0.50712]	[-1.75235]*
C	0.001475	-0.001705	0.008583
	(0.00422)	(0.00155)	(0.00146)
	[0.34949]	[-1.09881]	[5.88055]***
R-squared	0.434056	0.643693	0.079923
Adj. R-squared	0.424299	0.637550	0.064060
Sum sq. resids	0.429046	0.058021	0.051329
S.E. equation	0.049657	0.018261	0.017175
F-statistic	44.48371	104.7809	5.038206
Log likelihood	283.9187	461.9864	472.8925
Akaike AIC	-3.145154	-5.145914	-5.268455
Schwarz SC	-3.073653	-5.074414	-5.196954
Mean dependent	-0.001000	-0.008108	0.008379
S.D. dependent	0.065445	0.030331	0.017754

VAR IV – LAG 1-2

Sample (adjusted): 2002M04 2016M12
Included observations: 177 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.614720	0.044390	-0.032148
	(0.07658)	(0.02821)	(0.02600)
	[8.02760]***	[1.57346]	[-1.23627]
DLNIPCA(-2)	-0.052939	0.014896	0.000368
	(0.07837)	(0.02887)	(0.02661)
	[-0.67549]	[0.51590]	[0.01383]
DLNJRIGPM(-1)	0.417693	0.745626	-0.001689
	(0.20951)	(0.07719)	(0.07115)
	[1.99363]**	[9.65981]***	[-0.02373]
DLNJRIGPM(-2)	0.013211	0.013547	-0.130135
	(0.21332)	(0.07859)	(0.07244)
	[0.06193]	[0.17238]	[-1.79648]*
DLNM1(-1)	0.121999	-0.023590	-0.139708
	(0.22274)	(0.08206)	(0.07564)
	[0.54773]	[-0.28748]	[-1.84707]*
DLNM1(-2)	0.171241	0.073594	0.127190
	(0.21648)	(0.07976)	(0.07351)
	[0.79102]	[0.92275]	[1.73016]*
C	6.79E-05	-0.002393	0.007283
	(0.00471)	(0.00174)	(0.00160)
	[0.01441]	[-1.37780]	[4.55006]***
R-squared	0.439376	0.646138	0.114276
Adj. R-squared	0.419590	0.633648	0.083015
Sum sq. resids	0.424440	0.057610	0.048945
S.E. equation	0.049967	0.018409	0.016968

VAR IV – LAG 1-3

Sample (adjusted): 2002M05 2016M12
Included observations: 176 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.603263	0.043073	-0.036909
	(0.07712)	(0.02854)	(0.02591)
	[7.82242]***	[1.50933]	[-1.42428]
DLNIPCA(-2)	0.001625	0.019346	0.018432
	(0.09168)	(0.03393)	(0.03081)
	[0.01773]	[0.57021]	[0.59830]
DLNIPCA(-3)	-0.074258	-0.004458	-0.019710
	(0.07872)	(0.02913)	(0.02645)
	[-0.94330]	[-0.15304]	[-0.74511]
DLNJRIGPM(-1)	0.412929	0.739451	0.005645
	(0.21068)	(0.07796)	(0.07079)
	[1.95997]*	[9.48479]***	[0.07974]
DLNJRIGPM(-2)	0.131473	0.032057	-0.063569
	(0.26538)	(0.09820)	(0.08917)
	[0.49541]	[0.32644]	[-0.71287]
DLNJRIGPM(-3)	-0.093376	-0.007604	-0.086649
	(0.21595)	(0.07991)	(0.07256)
	[-0.43240]	[-0.09516]	[-1.19412]
DLNM1(-1)	0.062829	-0.031412	-0.175822
	(0.22839)	(0.08452)	(0.07675)
	[0.27509]	[-0.37167]	[-2.29098]**
DLNM1(-2)	0.150354	0.078495	0.106551
	(0.22615)	(0.08369)	(0.07599)
	[0.66483]	[0.93795]	[1.40211]
DLNM1(-3)	0.295775	0.091271	0.053709
	(0.21963)	(0.08128)	(0.07380)

F-statistic	22.20563	51.73544	3.655560
Log likelihood	282.7803	459.5217	473.9461
Akaike AIC	-3.116162	-5.113240	-5.276227
Schwarz SC	-2.990552	-4.987630	-5.150616
Mean dependent	-0.001180	-0.008074	0.008249
S.D. dependent	0.065587	0.030414	0.017719

	[1.34667]	[1.12298]	[0.72775]
C	-0.001649	-0.003037	0.007009
	(0.00508)	(0.00188)	(0.00171)
	[-0.32430]	[-1.61427]	[4.10321]***
R-squared	0.449421	0.649306	0.135789
Adj. R-squared	0.419571	0.630293	0.088934
Sum sq. resids	0.416298	0.057005	0.047005
S.E. equation	0.050078	0.018531	0.016827
F-statistic	15.05567	34.14975	2.898070
Log likelihood	282.3886	457.3551	474.3300
Akaike AIC	-3.095325	-5.083581	-5.276477
Schwarz SC	-2.915184	-4.903440	-5.096336
Mean dependent	-0.001357	-0.007984	0.008082
S.D. dependent	0.065731	0.030477	0.017630

Nota: Foram utilizadas 178 observações depois dos ajustamentos. Os desvios-padrão encontram-se em ( ) e t-estatístico em [ ].
Fonte: O autor, 2019.

Quadro 8 - Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 6 passos à frente.

VAR I – LAG 1-1

Sample (adjusted): 2002M03 2017M06
Included observations: 184 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.612676	0.063381	-0.023794
	(0.05875)	(0.02185)	(0.04319)
	[10.4294]***	[2.90041]***	[-0.55087]
DLNJRIGPM(-1)	0.393376	0.758156	0.126373
	(0.13091)	(0.04870)	(0.09625)
	[3.00498]***	[15.5691]***	[1.31290]
DLNCAMBIO(-1)	0.157444	-0.030610	0.381830
	(0.09338)	(0.03474)	(0.06866)
	[1.68602]*	[-0.88121]	[5.56097]***
C	0.000751	-0.002291	0.002085
	(0.00385)	(0.00143)	(0.00283)
	[0.19506]	[-1.60006]	[0.73642]
R-squared	0.476353	0.642469	0.160446
Adj. R-squared	0.467625	0.636510	0.146454
Sum sq. resids	0.448774	0.062099	0.242626
S.E. equation	0.049932	0.018574	0.036714
F-statistic	54.58095	107.8176	11.46655
Log likelihood	292.4032	474.3598	348.9828
Akaike AIC	-3.134817	-5.112607	-3.749813
Schwarz SC	-3.064927	-5.042717	-3.679923
Mean dependent	-0.004992	-0.009346	0.001680
S.D. dependent	0.068433	0.030808	0.039739

VAR I – LAG 1-2

Sample (adjusted): 2002M04 2017M06
Included observations: 183 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.643452	0.044917	-0.006422
	(0.07638)	(0.02838)	(0.05610)
	[8.42422]***	[1.58294]	[-0.11447]
DLNIPCA(-2)	-0.043412	0.024322	-0.027018
	(0.07627)	(0.02834)	(0.05602)
	[-0.56916]	[0.85835]	[-0.48228]
DLNJRIGPM(-1)	0.464387	0.726639	0.157829
	(0.20737)	(0.07704)	(0.15231)
	[2.23944]**	[9.43237]***	[1.03623]
DLNJRIGPM(-2)	-0.074485	0.032141	-0.027011
	(0.20869)	(0.07753)	(0.15328)
	[-0.35692]	[0.41457]	[-0.17622]
DLNCAMBIO(-1)	0.158918	-0.042020	0.387437
	(0.10273)	(0.03816)	(0.07545)
	[1.54700]	[-1.10108]	[5.13489]***
DLNCAMBIO(-2)	-0.004157	0.028257	-0.008071
	(0.10339)	(0.03841)	(0.07594)
	[-0.04020]	[0.73565]	[-0.10628]
C	0.000502	-0.002270	0.002323
	(0.00392)	(0.00146)	(0.00288)
	[0.12817]	[-1.55880]	[0.80695]
R-squared	0.478538	0.645384	0.163967
Adj. R-squared	0.460761	0.633295	0.135466
Sum sq. resids	0.446226	0.061584	0.240731

S.E. equation	0.050353	0.018706	0.036984
F-statistic	26.91879	53.38532	5.752987
Log likelihood	290.8363	472.0446	347.3052
Akaike AIC	-3.102036	-5.082455	-3.719182
Schwarz SC	-2.979269	-4.959688	-3.596415
Mean dependent	-0.005188	-0.009320	0.001856
S.D. dependent	0.068569	0.030890	0.039776

VAR I – LAG 1-3

Sample (adjusted): 2002M05 2017M06
Included observations: 182 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.637624	0.044788	-0.005426
	(0.07677)	(0.02856)	(0.05681)
	[8.30517]***	[1.56806]	[-0.09552]
DLNIPCA(-2)	-0.010856	0.032027	-0.045922
	(0.09136)	(0.03399)	(0.06760)
	[-0.11883]	[0.94227]	[-0.67934]
DLNIPCA(-3)	-0.056684	-0.017813	0.029378
	(0.07680)	(0.02857)	(0.05682)
	[-0.73812]	[-0.62345]	[0.51701]
DLNJRIGPM(-1)	0.461236	0.722819	0.149810
	(0.20856)	(0.07759)	(0.15432)
	[2.21156]**	[9.31572]***	[0.97080]
DLNJRIGPM(-2)	0.053933	0.060799	-0.003450
	(0.26176)	(0.09739)	(0.19368)
	[0.20604]	[0.62431]	[-0.01781]
DLNJRIGPM(-3)	-0.125102	-0.020109	-0.035849
	(0.20942)	(0.07791)	(0.15496)
	[-0.59737]	[-0.25810]	[-0.23135]
DLNCAMBIO(-1)	0.159081	-0.044941	0.389098

VAR II – LAG 1-1

Sample (adjusted): 2002M03 2017M06
Included observations: 184 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.595768	-0.055854	0.058222	-0.026787
	(0.05942)	(0.34858)	(0.02177)	(0.04158)
	[10.0265]***	[-0.16023]	[2.67480]***	[-0.64424]
DLNM4BM(-1)	0.010618	-0.339921	-0.005880	-0.040682
	(0.01194)	(0.07007)	(0.00438)	(0.00836)
	[0.88900]	[-4.85129]***	[-1.34400]	[-4.86749]***
DLNJRIPCA(-1)	0.447615	0.433652	0.780923	0.083174
	(0.12897)	(0.75658)	(0.04724)	(0.09025)
	[3.47077]***	[0.57317]	[16.5294]***	[0.92162]
DLNCAMBIO(-1)	0.142724	-0.726002	-0.006290	0.373403
	(0.09318)	(0.54663)	(0.03413)	(0.06520)
	[1.53171]	[-1.32813]	[-0.18426]	[5.72669]***
C	0.000850	0.008979	-0.001989	0.001787
	(0.00379)	(0.02226)	(0.00139)	(0.00266)
	[0.22408]	[0.40336]	[-1.43115]	[0.67293]
R-squared	0.486803	0.123551	0.680452	0.254764
Adj. R-squared	0.475334	0.103966	0.673311	0.238110
Sum sq. resids	0.439818	15.13665	0.059023	0.215369
S.E. equation	0.049569	0.290796	0.018159	0.034687
F-statistic	42.44840	6.308329	95.29165	15.29806

	(0.10334)	(0.03845)	(0.07646)
	[1.53943]	[-1.16894]	[5.08876]***
DLNCAMBIO(-2)	-0.059157	0.011485	-0.025804
	(0.11194)	(0.04165)	(0.08283)
	[-0.52848]	[0.27578]	[-0.31154]
DLNCAMBIO(-3)	0.148481	0.048139	0.047937
	(0.10380)	(0.03862)	(0.07680)
	[1.43049]	[1.24659]	[0.62416]
C	0.000194	-0.002216	0.002121
	(0.00397)	(0.00148)	(0.00293)
	[0.04896]	[-1.50210]	[0.72284]
R-squared	0.487360	0.650444	0.166622
Adj. R-squared	0.460536	0.632154	0.123015
Sum sq. resids	0.438040	0.060631	0.239823
S.E. equation	0.050465	0.018775	0.037341
F-statistic	18.16867	35.56146	3.820994
Log likelihood	290.4333	470.3866	345.2526
Akaike AIC	-3.081684	-5.059194	-3.684095
Schwarz SC	-2.905640	-4.883149	-3.508051
Mean dependent	-0.005381	-0.009239	0.001928
S.D. dependent	0.068709	0.030956	0.039874

Log likelihood	294.2577	-31.28553	479.0338	359.9463
Akaike AIC	-3.144105	0.394408	-5.152541	-3.858112
Schwarz SC	-3.056743	0.481770	-5.065179	-3.770749
Mean dependent	-0.004992	0.003278	-0.008680	0.001680
S.D. dependent	0.068433	0.307203	0.031770	0.039739

VAR II – LAG 1-2

Sample (adjusted): 2002M04 2017M06
Included observations: 183 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.633765	0.185341	0.050601	-0.032997
	(0.07567)	(0.44582)	(0.02815)	(0.05344)
	[8.37488]***	[0.41573]	[1.79780]*	[-0.61750]
DLNIPCA(-2)	-0.061663	-0.418199	0.007644	-0.003936
	(0.07516)	(0.44276)	(0.02795)	(0.05307)
	[-0.82046]	[-0.94452]	[0.27347]	[-0.07417]

VAR II – LAG 1-3

Sample (adjusted): 2002M05 2017M06
Included observations: 182 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.629187	0.025489	0.046912	-0.036854
	(0.07777)	(0.42906)	(0.02889)	(0.05498)
	[8.09037]***	[0.05941]	[1.62381]	[-0.67029]
DLNIPCA(-2)	-0.032577	-0.757105	0.019852	-0.002799
	(0.09148)	(0.50470)	(0.03398)	(0.06468)
	[-0.35611]	[-1.50011]	[0.58417]	[-0.04327]

DLNM4BM(-1)	0.000601	-0.375774	-0.005777	-0.040547
	(0.01297)	(0.07638)	(0.00482)	(0.00916)
	[0.04637]	[-4.91966]***	[-1.19803]	[-4.42886]***
DLNM4BM(-2)	-0.030290	-0.135402	0.000653	0.004048
	(0.01370)	(0.08074)	(0.00510)	(0.00968)
	[-2.21025]**	[-1.67707]*	[0.12804]	[0.41832]
DLNJRIPCA(-1)	0.439871	0.792660	0.755674	-0.034242
	(0.21034)	(1.23917)	(0.07823)	(0.14853)
	[2.09125]**	[0.63967]	[9.65934]***	[-0.23055]
DLNJRIPCA(-2)	0.018645	-0.364059	0.029658	0.160353
	(0.21258)	(1.25238)	(0.07907)	(0.15011)
	[0.08771]	[-0.29069]	[0.37510]	[1.06823]
DLNCAMBIO(-1)	0.061134	-1.303754	-0.010439	0.400636
	(0.10784)	(0.63532)	(0.04011)	(0.07615)
	[0.56689]	[-2.05213]**	[-0.26027]	[5.26119]***
DLNCAMBIO(-2)	0.000896	0.578061	0.016376	-0.043036
	(0.10212)	(0.60164)	(0.03798)	(0.07211)
	[0.00878]	[0.96082]	[0.43114]	[-0.59679]
C	0.000932	0.009196	-0.001929	0.002289
	(0.00381)	(0.02247)	(0.00142)	(0.00269)
	[0.24449]	[0.40928]	[-1.35968]	[0.85002]
R-squared	0.503520	0.146196	0.681618	0.264304
Adj. R-squared	0.480693	0.106941	0.666979	0.230479
Sum sq. resids	0.424849	14.74536	0.058772	0.211839
S.E. equation	0.049413	0.291107	0.018378	0.034892
F-statistic	22.05840	3.724232	46.56410	7.813851
Log likelihood	295.3283	-29.21772	476.3217	359.0036
Akaike AIC	-3.129271	0.417680	-5.107341	-3.825176
Schwarz SC	-2.971427	0.575524	-4.949497	-3.667333
Mean dependent	-0.005188	0.003362	-0.008622	0.001856

DLNIPCA(-3)	-0.049989	0.821625	-0.015778	0.004841
	(0.07624)	(0.42062)	(0.02832)	(0.05390)
	[-0.65568]	[1.95335]*	[-0.55711]	[0.08982]
DLNM4BM(-1)	-0.001106	-0.377868	-0.006877	-0.041814
	(0.01327)	(0.07318)	(0.00493)	(0.00938)
	[-0.08336]	[-5.16326]***	[-1.39568]	[-4.45858]***
DLNM4BM(-2)	-0.028464	-0.250350	-0.000151	0.003666
	(0.01496)	(0.08255)	(0.00556)	(0.01058)
	[-1.90235]*	[-3.03267]***	[-0.02708]	[0.34652]
DLNM4BM(-3)	0.000245	-0.237189	-0.003664	-0.004224
	(0.01415)	(0.07805)	(0.00526)	(0.01000)
	[0.01733]	[-3.03880]***	[-0.69726]	[-0.42235]
DLNJRIPCA(-1)	0.432509	0.884534	0.750070	-0.040683
	(0.21249)	(1.17231)	(0.07893)	(0.15023)
	[2.03546]**	[0.75452]	[9.50245]***	[-0.27081]
DLNJRIPCA(-2)	0.104050	-1.845401	0.077574	0.236684
	(0.27070)	(1.49346)	(0.10056)	(0.19138)
	[0.38438]	[-1.23565]	[0.77144]	[1.23671]
DLNJRIPCA(-3)	-0.077310	1.365018	-0.049678	-0.098352
	(0.21520)	(1.18727)	(0.07994)	(0.15214)
	[-0.35925]	[1.14972]	[-0.62143]	[-0.64644]
DLNCAMBIO(-1)	0.069957	-1.393117	-0.009342	0.407787
	(0.10948)	(0.60399)	(0.04067)	(0.07740)
	[0.63901]	[-2.30652]***	[-0.22971]	[5.26860]***
DLNCAMBIO(-2)	-0.051317	0.708006	-0.008564	-0.087888
	(0.11794)	(0.65067)	(0.04381)	(0.08338)
	[-0.43512]	[1.08812]	[-0.19548]	[-1.05406]
DLNCAMBIO(-3)	0.121517	-1.689942	0.040393	0.083508

S.D. dependent	0.068569	0.308044	0.031847	0.039776

	(0.10340)	(0.57046)	(0.03841)	(0.07310)
	[1.17522]	[-2.96242]***	[1.05161]	[1.14234]
C	0.000661	0.013774	-0.001939	0.002027
	(0.00388)	(0.02140)	(0.00144)	(0.00274)
	[0.17043]	[0.64367]	[-1.34563]	[0.73922]
R-squared	0.509216	0.260615	0.685965	0.271593
Adj. R-squared	0.474367	0.208115	0.663667	0.219872
Sum sq. resids	0.419365	12.76467	0.057871	0.209615
S.E. equation	0.049814	0.274828	0.018505	0.035218
F-statistic	14.61224	4.964041	30.76303	5.251096
Log likelihood	294.3981	-16.43023	474.6263	357.5037
Akaike AIC	-3.092287	0.323409	-5.072816	-3.785755
Schwarz SC	-2.863429	0.552267	-4.843959	-3.556898
Mean dependent	-0.005381	0.003796	-0.008525	0.001928
S.D. dependent	0.068709	0.308838	0.031908	0.039874

VAR III – LAG 1-1

Sample (adjusted): 2002M03 2017M06
Included observations: 184 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.609056	-0.010403	0.064039
	(0.05914)	(0.07529)	(0.02172)
	[10.2992]***	[-0.13817]	[2.94804]***
DLNPRODIND(-1)	0.024508	-0.218857	-0.034396
	(0.05707)	(0.07266)	(0.02096)
	[0.42944]	[-3.01198]***	[-1.64079]*
DLNJRIGPM(-1)	0.417666	-0.142795	0.749946
	(0.13142)	(0.16733)	(0.04828)
	[3.17809]***	[-0.85338]	[15.5349]***
C	0.001180	0.000234	-0.002371
	(0.00387)	(0.00493)	(0.00142)
	[0.30487]	[0.04749]	[-1.66779]*

VAR III – LAG 1-2

Sample (adjusted): 2002M04 2017M06
Included observations: 183 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.637755	-0.007426	0.047585
	(0.07609)	(0.09532)	(0.02783)
	[8.38188]***	[-0.07790]	[1.71006]*
DLNIPCA(-2)	-0.044564	-0.005536	0.022204
	(0.07648)	(0.09581)	(0.02797)
	[-0.58273]	[-0.05778]	[0.79389]
DLNPRODIND(-1)	0.027996	-0.181180	-0.028182
	(0.05907)	(0.07400)	(0.02160)
	[0.47396]	[-2.44833]***	[-1.30457]
DLNPRODIND(-2)	0.010247	0.156557	0.028668
	(0.05992)	(0.07507)	(0.02191)
	[0.17102]	[2.08560]**	[1.30825]

R-squared	0.468627	0.051270	0.646218
Adj. R-squared	0.459771	0.035458	0.640322
Sum sq. resids	0.455394	0.738249	0.061448
S.E. equation	0.050299	0.064042	0.018476
F-statistic	52.91513	3.242456	109.5959
Log likelihood	291.0558	246.6090	475.3296
Akaike AIC	-3.120172	-2.637054	-5.123148
Schwarz SC	-3.050282	-2.567165	-5.053258
Mean dependent	-0.004992	0.001286	-0.009346
S.D. dependent	0.068433	0.065209	0.030808

DLNJRIGPM(-1)	0.468611	0.009289	0.731947
	(0.20949)	(0.26245)	(0.07661)
	[2.23691]**	[0.03539]	[9.55364]***
DLNJRIGPM(-2)	-0.043035	-0.147085	0.023427
	(0.20924)	(0.26214)	(0.07652)
	[-0.20567]	[-0.56109]	[0.30615]
C	0.000984	-0.000362	-0.002292
	(0.00394)	(0.00493)	(0.00144)
	[0.25001]	[-0.07340]	[-1.59246]
R-squared	0.471028	0.074181	0.651385
Adj. R-squared	0.452995	0.042619	0.639501
Sum sq. resids	0.452653	0.710449	0.060542
S.E. equation	0.050714	0.063535	0.018547
F-statistic	26.12011	2.350334	54.80922
Log likelihood	289.5279	248.2823	473.6063
Akaike AIC	-3.087736	-2.636964	-5.099522
Schwarz SC	-2.964969	-2.514197	-4.976755
Mean dependent	-0.005188	0.000720	-0.009320
S.D. dependent	0.068569	0.064933	0.030890

VAR III – LAG 1-3

Sample (adjusted): 2002M05 2017M06
Included observations: 182 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.632922	-0.011979	0.046901
	(0.07691)	(0.09558)	(0.02783)
	[8.22959]***	[-0.12533]	[1.68528]*
DLNIPCA(-2)	0.006783	0.015762	0.032565
	(0.09141)	(0.11360)	(0.03308)
	[0.07421]	[0.13874]	[0.98448]
DLNIPCA(-3)	-0.072614	-0.042822	-0.019339

VAR IV – LAG 1-1

Sample (adjusted): 2002M03 2017M06
Included observations: 184 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.613301	0.062989	-0.033341
	(0.05922)	(0.02193)	(0.02027)
	[10.3561]***	[2.87222]***	[-1.64515]
DLNJRIGPM(-1)	0.421823	0.752181	-0.102854
	(0.13125)	(0.04860)	(0.04491)
	[3.21394]***	[15.4760]***	[-2.29000]**
DLNM1(-1)	0.191650	-0.049353	-0.128608

	(0.07734)	(0.09612)	(0.02799)
	[-0.93888]	[-0.44551]	[-0.69100]
DLNPRODIND(-1)	0.029519	-0.166738	-0.034461
	(0.06069)	(0.07543)	(0.02196)
	[0.48635]	[-2.21051]**	[-1.56907]
DLNPRODIND(-2)	0.005167	0.139128	0.036035
	(0.06130)	(0.07618)	(0.02218)
	[0.08429]	[1.82622]*	[1.62449]
DLNPRODIND(-3)	-0.027138	-0.122631	0.046070
	(0.06149)	(0.07641)	(0.02225)
	[-0.44138]	[-1.60484]	[2.07068]**
DLNJRIGPM(-1)	0.490175	0.058066	0.718568
	(0.21245)	(0.26403)	(0.07688)
	[2.30722]***	[0.21992]	[9.34684]***
DLNJRIGPM(-2)	0.035877	-0.358465	0.065581
	(0.26623)	(0.33087)	(0.09634)
	[0.13476]	[-1.08339]	[0.68073]
DLNJRIGPM(-3)	-0.096866	0.213709	-0.016487
	(0.21115)	(0.26242)	(0.07641)
	[-0.45875]	[0.81438]	[-0.21578]
C	0.000940	-0.000192	-0.002201
	(0.00400)	(0.00497)	(0.00145)
	[0.23505]	[-0.03871]	[-1.52086]
R-squared	0.474240	0.094883	0.660848
Adj. R-squared	0.446730	0.047522	0.643101
Sum sq. resids	0.449250	0.693885	0.058826
S.E. equation	0.051107	0.063515	0.018494
F-statistic	17.23841	2.003403	37.23850
Log likelihood	288.1337	248.5737	473.1360
Akaike AIC	-3.056414	-2.621689	-5.089407

	(0.21153)	(0.07833)	(0.07239)
	[0.90601]	[-0.63004]	[-1.77663]*
C	-0.000306	-0.001992	0.008248
	(0.00420)	(0.00155)	(0.00144)
	[-0.07290]	[-1.28139]	[5.74156]***
R-squared	0.470498	0.641717	0.071536
Adj. R-squared	0.461673	0.635745	0.056062
Sum sq. resids	0.453792	0.062230	0.053143
S.E. equation	0.050210	0.018594	0.017183
F-statistic	53.31396	107.4652	4.622863
Log likelihood	291.3802	474.1665	488.6882
Akaike AIC	-3.123698	-5.110505	-5.268350
Schwarz SC	-3.053808	-5.040615	-5.198460
Mean dependent	-0.004992	-0.009346	0.008246
S.D. dependent	0.068433	0.030808	0.017685

Schwarz SC	-2.880370	-2.445645	-4.913362
Mean dependent	-0.005381	0.000570	-0.009239
S.D. dependent	0.068709	0.065081	0.030956

VAR IV – LAG 1-2

Sample (adjusted): 2002M04 2017M06

Included observations: 183 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.630397	0.047505	-0.032767
	(0.07599)	(0.02813)	(0.02548)
	[8.29599]***	[1.68884]*	[-1.28585]
DLNIPCA(-2)	-0.028068	0.024366	0.011177
	(0.07743)	(0.02866)	(0.02597)
	[-0.36250]	[0.85012]	[0.43045]
DLNJRIGPM(-1)	0.444697	0.731551	-0.005668
	(0.21019)	(0.07781)	(0.07049)
	[2.11570]**	[9.40208]***	[-0.08042]
DLNJRIGPM(-2)	0.001428	0.024320	-0.123771
	(0.21369)	(0.07910)	(0.07166)
	[0.00668]	[0.30744]	[-1.72717]*
DLNM1(-1)	0.207157	-0.026371	-0.134139
	(0.22181)	(0.08211)	(0.07438)
	[0.93396]	[-0.32118]	[-1.80339]*
DLNM1(-2)	0.205241	0.086832	0.143577
	(0.21540)	(0.07973)	(0.07223)
	[0.95285]	[1.08901]	[1.98770]**
C	-0.002150	-0.002801	0.006813
	(0.00464)	(0.00172)	(0.00156)
	[-0.46285]	[-1.62938]	[4.37419]***
R-squared	0.475043	0.645543	0.109086

VAR IV – LAG 1-3

Sample (adjusted): 2002M05 2017M06

Included observations: 182 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.618878	0.045046	-0.037496
	(0.07645)	(0.02834)	(0.02537)
	[8.09507]***	[1.58928]	[-1.47776]
DLNIPCA(-2)	0.009912	0.031736	0.026584
	(0.09117)	(0.03380)	(0.03026)
	[0.10873]	[0.93897]	[0.87860]
DLNIPCA(-3)	-0.051626	-0.010863	-0.015096
	(0.07785)	(0.02886)	(0.02584)
	[-0.66312]	[-0.37636]	[-0.58424]
DLNJRIGPM(-1)	0.434506	0.724015	0.001773
	(0.21140)	(0.07838)	(0.07016)
	[2.05534]**	[9.23771]***	[0.02526]
DLNJRIGPM(-2)	0.081693	0.038162	-0.055108
	(0.26565)	(0.09849)	(0.08817)
	[0.30751]	[0.38748]	[-0.62504]
DLNJRIGPM(-3)	-0.039161	0.006762	-0.090634
	(0.21609)	(0.08011)	(0.07172)
	[-0.18123]	[0.08441]	[-1.26377]
DLNM1(-1)	0.150284	-0.036427	-0.170506
	(0.22759)	(0.08438)	(0.07553)
	[0.66033]	[-0.43171]	[-2.25733]**
DLNM1(-2)	0.212536	0.095783	0.124156

Adj. R-squared	0.457146	0.633460	0.078714		(0.22494)	(0.08339)	(0.07465)
Sum sq. resids	0.449217	0.061557	0.050518		[0.94486]	[1.14856]	[1.66308]*
S.E. equation	0.050521	0.018702	0.016942				
F-statistic	26.54421	53.42245	3.591660	DLNM1(-3)	0.353175	0.119951	0.060986
Log likelihood	290.2250	472.0857	490.1685		(0.21908)	(0.08122)	(0.07271)
Akaike AIC	-3.095355	-5.082904	-5.280530		[1.61207]	[1.47683]	[0.83875]
Schwarz SC	-2.972588	-4.960136	-5.157763				
Mean dependent	-0.005188	-0.009320	0.008120	C	-0.004501	-0.003620	0.006451
S.D. dependent	0.068569	0.030890	0.017651		(0.00497)	(0.00184)	(0.00165)
					[-0.90584]	[-1.96496]**	[3.91205]***
				R-squared	0.484478	0.650930	0.130853
				Adj. R-squared	0.457503	0.632665	0.085374
				Sum sq. resids	0.440503	0.060546	0.048521
				S.E. equation	0.050607	0.018762	0.016796
				F-statistic	17.96026	35.63752	2.877233
				Log likelihood	289.9231	470.5131	490.6614
				Akaike AIC	-3.076078	-5.060584	-5.281993
				Schwarz SC	-2.900034	-4.884539	-5.105949
				Mean dependent	-0.005381	-0.009239	0.007958
				S.D. dependent	0.068709	0.030956	0.017562

Nota: Foram utilizadas 178 observações depois dos ajustamentos. Os desvios-padrão encontram-se em ( ) e t-estatístico em [ ].
Fonte: O autor, 2019.

Quadro 9- Estimações VAR com 1, 2 e 3 defasagens utilizadas para a previsão 3 passos à frente.

VAR I – LAG 1-1

Sample (adjusted): 2002M03 2017M09
Included observations: 187 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.606494	0.063572	-0.017883
	(0.05853)	(0.02326)	(0.04227)
	[10.3627]***	[2.73266]***	[-0.42303]
DLNJRIGPM(-1)	0.321411	0.731643	0.131827
	(0.12937)	(0.05142)	(0.09345)
	[2.48439]**	[14.2277]***	[1.41073]
DLNCAMBIO(-1)	0.160252	-0.013445	0.379151
	(0.09417)	(0.03743)	(0.06802)
	[1.70165]*	[-0.35918]	[5.57395]***
C	0.000759	-0.002698	0.001991
	(0.00388)	(0.00154)	(0.00280)
	[0.19538]	[-1.74805]*	[0.70976]
R-squared	0.466636	0.606637	0.159848
Adj. R-squared	0.457893	0.600189	0.146075
Sum sq. resids	0.467387	0.073845	0.243844
S.E. equation	0.050537	0.020088	0.036503
F-statistic	53.36851	94.07323	11.60589
Log likelihood	294.8830	467.4076	355.7169
Akaike AIC	-3.111048	-4.956231	-3.761678
Schwarz SC	-3.041934	-4.887117	-3.692563
Mean dependent	-0.005804	-0.010232	0.001386
S.D. dependent	0.068639	0.031769	0.039502

VAR I – LAG 1-2

Sample (adjusted): 2002M04 2017M09
Included observations: 186 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.622361	0.026136	-0.001580
	(0.07619)	(0.02989)	(0.05500)
	[8.16881]***	[0.87429]	[-0.02873]
DLNIPCA(-2)	-0.035055	0.046199	-0.024491
	(0.07586)	(0.02977)	(0.05477)
	[-0.46208]	[1.55200]	[-0.44719]
DLNJRIGPM(-1)	0.248017	0.624156	0.155679
	(0.18804)	(0.07378)	(0.13575)
	[1.31894]	[8.45915]***	[1.14679]
DLNJRIGPM(-2)	0.121974	0.132931	-0.020377
	(0.19200)	(0.07534)	(0.13861)
	[0.63528]	[1.76446]*	[-0.14701]
DLNCAMBIO(-1)	0.159597	-0.028966	0.387407
	(0.10365)	(0.04067)	(0.07483)
	[1.53972]	[-0.71219]	[5.17723]***
DLNCAMBIO(-2)	-0.020077	0.024711	-0.013918
	(0.10403)	(0.04082)	(0.07510)
	[-0.19298]	[0.60535]	[-0.18531]
C	0.000909	-0.002460	0.002216
	(0.00395)	(0.00155)	(0.00285)
	[0.23007]	[-1.58662]	[0.77654]
R-squared	0.469297	0.619146	0.163235
Adj. R-squared	0.451508	0.606380	0.135187
Sum sq. resids	0.464338	0.071491	0.241998

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
S.E. equation	0.050932	0.019985	0.036769
F-statistic	26.38139	48.49937	5.819838
Log likelihood	293.4162	467.4225	354.0228
Akaike AIC	-3.079744	-4.950779	-3.731428
Schwarz SC	-2.958345	-4.829380	-3.610029
Mean dependent	-0.006001	-0.010211	0.001558
S.D. dependent	0.068771	0.031854	0.039538

VAR I – LAG 1-3

Sample (adjusted): 2002M05 2017M09

Included observations: 185 after adjustments

	DLNIPCA	DLNJRIGPM	DLNCAMBIO
DLNIPCA(-1)	0.617979	0.026692	-0.000518
	(0.07596)	(0.03013)	(0.05562)
	[8.13598]***	[0.88580]	[-0.00931]
DLNIPCA(-2)	0.017888	0.052781	-0.042332
	(0.08980)	(0.03563)	(0.06576)
	[0.19920]	[1.48156]	[-0.64377]
DLNIPCA(-3)	-0.082160	-0.013885	0.028738
	(0.07609)	(0.03019)	(0.05572)
	[-1.07978]	[-0.45998]	[0.51578]
DLNJRIGPM(-1)	0.300237	0.628964	0.152794
	(0.19084)	(0.07571)	(0.13974)
	[1.57327]	[8.30773]***	[1.09341]
DLNJRIGPM(-2)	0.308245	0.160206	0.011237
	(0.22788)	(0.09040)	(0.16686)
	[1.35268]	[1.77213]**	[0.06734]
DLNJRIGPM(-3)	-0.253182	-0.031324	-0.052618
	(0.19986)	(0.07929)	(0.14635)
	[-1.26677]	[-0.39505]	[-0.35953]
DLNCAMBIO(-1)	0.157802	-0.031563	0.388882

VAR II – LAG 1-1

Sample (adjusted): 2002M03 2017M09

Included observations: 187 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.589666	-0.052386	0.058357	-0.020291
	(0.05941)	(0.34104)	(0.02299)	(0.04082)
	[9.92499]***	[-0.15360]	[2.53851]**	[-0.49710]
DLNM4BM(-1)	0.010454	-0.339831	-0.005844	-0.040524
	(0.01210)	(0.06948)	(0.00468)	(0.00832)
	[0.86372]	[-4.89134]***	[-1.24779]	[-4.87342]***
DLNJRIPCA(-1)	0.376359	0.423199	0.757806	0.092229
	(0.12778)	(0.73349)	(0.04944)	(0.08779)
	[2.94541]***	[0.57697]	[15.3272]***	[1.05058]
DLNCAMBIO(-1)	0.147468	-0.723765	0.009819	0.370205
	(0.09409)	(0.54008)	(0.03641)	(0.06464)
	[1.56737]	[-1.34010]	[0.26972]	[5.72715]***
C	0.000959	0.008848	-0.002318	0.001678
	(0.00383)	(0.02201)	(0.00148)	(0.00263)
	[0.25018]	[0.40204]	[-1.56241]	[0.63690]
R-squared	0.475745	0.123550	0.653707	0.252859
Adj. R-squared	0.464223	0.104287	0.646096	0.236439
Sum sq. resids	0.459405	15.13793	0.068782	0.216848
S.E. equation	0.050241	0.288401	0.019440	0.034518
F-statistic	41.28981	6.413962	85.89147	15.39885

	(0.10351)	(0.04106)	(0.07580)
	[1.52449]	[-0.76860]	[5.13061]***
DLNCAMBIO(-2)	-0.071607	0.012228	-0.030541
	(0.11204)	(0.04445)	(0.08204)
	[-0.63914]	[0.27512]	[-0.37227]
DLNCAMBIO(-3)	0.166671	0.040053	0.048445
	(0.10374)	(0.04116)	(0.07596)
	[1.60662]	[0.97320]	[0.63773]
C	0.000333	-0.002456	0.001980
	(0.00397)	(0.00157)	(0.00291)
	[0.08384]	[-1.55979]	[0.68124]
R-squared	0.485537	0.622777	0.166215
Adj. R-squared	0.459079	0.603377	0.123335
Sum sq. resids	0.449459	0.070738	0.240999
S.E. equation	0.050679	0.020105	0.037110
F-statistic	18.35119	32.10190	3.876247
Log likelihood	294.3525	465.3902	352.0034
Akaike AIC	-3.074081	-4.923137	-3.697334
Schwarz SC	-2.900008	-4.749063	-3.523261
Mean dependent	-0.006196	-0.010136	0.001627
S.D. dependent	0.068906	0.031924	0.039634
Log likelihood	296.4935	-30.29136	474.0491	366.6872
Akaike AIC	-3.117578	0.377448	-5.016567	-3.868312
Schwarz SC	-3.031185	0.463841	-4.930174	-3.781919
Mean dependent	-0.005804	0.003129	-0.009616	0.001386
S.D. dependent	0.068639	0.304729	0.032678	0.039502

VAR II – LAG 1-2

Sample (adjusted): 2002M04 2017M09
Included observations: 186 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.613263	0.170740	0.032375	-0.023704
	(0.07546)	(0.43636)	(0.02943)	(0.05248)
	[8.12705]***	[0.39128]	[1.09989]	[-0.45167]
DLNIPCA(-2)	-0.054449	-0.383519	0.027835	-0.005870
	(0.07476)	(0.43233)	(0.02916)	(0.05200)
	[-0.72828]	[-0.88710]	[0.95443]	[-0.11289]

VAR II – LAG 1-3

Sample (adjusted): 2002M05 2017M09
Included observations: 185 after adjustments

	DLNIPCA	DLNM4BM	DLNJRIPCA	DLNCAMBIO
DLNIPCA(-1)	0.609256	-0.014737	0.029689	-0.025903
	(0.07700)	(0.42045)	(0.03021)	(0.05396)
	[7.91261]***	[-0.03505]	[0.98283]	[-0.48003]
DLNIPCA(-2)	-0.001121	-0.659830	0.040286	-0.009784
	(0.08975)	(0.49009)	(0.03521)	(0.06290)
	[-0.01249]	[-1.34634]	[1.14409]	[-0.15556]

DLNM4BM(-1)	-0.001580	-0.377087	-0.006569	-0.040115
	(0.01307)	(0.07560)	(0.00510)	(0.00909)
	[-0.12084]	[-4.98773]***	[-1.28811]	[-4.41188]***
DLNM4BM(-2)	-0.032393	-0.135491	0.000740	0.004352
	(0.01382)	(0.07994)	(0.00539)	(0.00961)
	[-2.34325]**	[-1.69494]*	[0.13715]	[0.45267]
DLNJRIPCA(-1)	0.233198	0.617284	0.655348	0.005196
	(0.19231)	(1.11206)	(0.07502)	(0.13374)
	[1.21261]	[0.55508]	[8.73618]***	[0.03885]
DLNJRIPCA(-2)	0.204273	-0.175630	0.128806	0.129279
	(0.19690)	(1.13862)	(0.07681)	(0.13694)
	[1.03743]	[-0.15425]	[1.67700]*	[0.94407]
DLNCAMBIO(-1)	0.062773	-1.282210	0.005241	0.398224
	(0.10859)	(0.62796)	(0.04236)	(0.07552)
	[0.57805]	[-2.04187]**	[0.12374]	[5.27291]
DLNCAMBIO(-2)	-0.011275	0.553183	0.012671	-0.046303
	(0.10269)	(0.59381)	(0.04006)	(0.07142)
	[-0.10980]	[0.93159]	[0.31633]	[-0.64836]
C	0.001336	0.008764	-0.002094	0.002177
	(0.00384)	(0.02223)	(0.00150)	(0.00267)
	[0.34758]	[0.39432]	[-1.39690]	[0.81458]
R-squared	0.495382	0.145199	0.661612	0.261611
Adj. R-squared	0.472575	0.106564	0.646317	0.228237
Sum sq. resids	0.441514	14.76381	0.067180	0.213547
S.E. equation	0.049944	0.288810	0.019482	0.034734
F-statistic	21.72006	3.758213	43.25849	7.838866
Log likelihood	298.1035	-28.30074	473.2067	365.6545
Akaike AIC	-3.108640	0.401083	-4.991470	-3.834994
Schwarz SC	-2.952556	0.557168	-4.835385	-3.678910
Mean dependent	-0.006001	0.003212	-0.009565	0.001558

DLNIPCA(-3)	-0.078377	0.753925	-0.014577	0.010646
	(0.07538)	(0.41161)	(0.02957)	(0.05283)
	[-1.03976]	[1.83163]*	[-0.49290]	[0.20153]
DLNM4BM(-1)	-0.003599	-0.383740	-0.007464	-0.041092
	(0.01327)	(0.07247)	(0.00521)	(0.00930)
	[-0.27115]	[-5.29484]***	[-1.43349]	[-4.41776]***
DLNM4BM(-2)	-0.029171	-0.250836	0.000114	0.004043
	(0.01502)	(0.08200)	(0.00589)	(0.01052)
	[-1.94262]*	[-3.05914]***	[0.01932]	[0.38416]
DLNM4BM(-3)	-0.000562	-0.238515	-0.003666	-0.003900
	(0.01420)	(0.07756)	(0.00557)	(0.00995)
	[-0.03959]	[-3.07518]***	[-0.65778]	[-0.39181]
DLNJRIPCA(-1)	0.269356	0.462690	0.663168	0.010789
	(0.19530)	(1.06646)	(0.07662)	(0.13687)
	[1.37916]	[0.43386]	[8.65503]***	[0.07882]
DLNJRIPCA(-2)	0.361627	-1.133560	0.173759	0.178319
	(0.23746)	(1.29663)	(0.09316)	(0.16641)
	[1.52292]	[-0.87424]	[1.86517]*	[1.07155]
DLNJRIPCA(-3)	-0.208361	0.998519	-0.062264	-0.079911
	(0.20589)	(1.12427)	(0.08078)	(0.14429)
	[-1.01200]	[0.88815]	[-0.77083]	[-0.55382]
DLNCAMBIO(-1)	0.076637	-1.365150	0.006717	0.404842
	(0.10950)	(0.59794)	(0.04296)	(0.07674)
	[0.69986]	[-2.28310]**	[0.15635]	[5.27548]***
DLNCAMBIO(-2)	-0.070771	0.644410	-0.008199	-0.088063
	(0.11785)	(0.64353)	(0.04624)	(0.08259)
	[-0.60050]	[1.00136]	[-0.17733]	[-1.06624]
DLNCAMBIO(-3)	0.139672	-1.651682	0.032378	0.080571

S.D. dependent	0.068771	0.305549	0.032759	0.039538

	(0.10335)	(0.56435)	(0.04055)	(0.07243)
	[1.35142]	[-2.92668]***	[0.79851]	[1.11239]
C	0.000830	0.013603	-0.002142	0.001905
	(0.00389)	(0.02121)	(0.00152)	(0.00272)
	[0.21372]	[0.64124]	[-1.40552]	[0.69951]
R-squared	0.506999	0.256177	0.665607	0.268153
Adj. R-squared	0.472603	0.204282	0.642277	0.217093
Sum sq. resids	0.430709	12.84239	0.066293	0.211535
S.E. equation	0.050041	0.273249	0.019632	0.035069
F-statistic	14.74028	4.936472	28.53037	5.251806
Log likelihood	298.2940	-15.75024	471.3937	364.0657
Akaike AIC	-3.084260	0.310813	-4.955608	-3.795305
Schwarz SC	-2.857964	0.537109	-4.729312	-3.569010
Mean dependent	-0.006196	0.003638	-0.009474	0.001627
S.D. dependent	0.068906	0.306323	0.032824	0.039634

VAR III – LAG 1-1

Sample (adjusted): 2002M03 2017M09
Included observations: 187 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.602832	-0.019684	0.063740
	(0.05891)	(0.07377)	(0.02303)
	[10.2327]***	[-0.26683]	[2.76709]***
DLNPRODIND(-1)	0.026563	-0.218912	-0.042260
	(0.05761)	(0.07213)	(0.02252)
	[0.46112]	[-3.03486]***	[-1.87622]*
DLNJRIGPM(-1)	0.344841	-0.125088	0.724950
	(0.12994)	(0.16271)	(0.05081)
	[2.65386]**	[-0.76879]	[14.2687]***
C	0.001165	0.000543	-0.002717
	(0.00390)	(0.00489)	(0.00153)
	[0.29843]	[0.11111]	[-1.78012]*

VAR III – LAG 1-2

Sample (adjusted): 2002M04 2017M09
Included observations: 186 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.613911	-0.003531	0.028912
	(0.07568)	(0.09326)	(0.02910)
	[8.11147]***	[-0.03786]	[0.99357]
DLNIPCA(-2)	-0.033493	-0.016185	0.043212
	(0.07588)	(0.09350)	(0.02917)
	[-0.44139]	[-0.17310]	[1.48113]
DLNPRODIND(-1)	0.033865	-0.181834	-0.032613
	(0.05956)	(0.07339)	(0.02290)
	[0.56856]	[-2.47762]**	[-1.42411]
DLNPRODIND(-2)	0.019720	0.157758	0.036663
	(0.06008)	(0.07403)	(0.02310)
	[0.32825]	[2.13111]**	[1.58724]

R-squared	0.458826	0.051150	0.613789
Adj. R-squared	0.449954	0.035595	0.607458
Sum sq. resids	0.474232	0.743580	0.072503
S.E. equation	0.050906	0.063744	0.019905
F-statistic	51.71786	3.288364	96.94489
Log likelihood	293.5237	251.4692	469.1232
Akaike AIC	-3.096510	-2.646729	-4.974580
Schwarz SC	-3.027396	-2.577615	-4.905465
Mean dependent	-0.005804	0.001542	-0.010232
S.D. dependent	0.068639	0.064910	0.031769

DLNJRIGPM(-1)	0.256683	0.081824	0.638282
	(0.19100)	(0.23534)	(0.07344)
	[1.34389]	[0.34768]	[8.69176]***
DLNJRIGPM(-2)	0.151844	-0.220047	0.119167
	(0.19252)	(0.23721)	(0.07402)
	[0.78873]	[-0.92764]	[1.60996]
C	0.001339	-0.000258	-0.002442
	(0.00396)	(0.00488)	(0.00152)
	[0.33775]	[-0.05273]	[-1.60217]
R-squared	0.462787	0.076762	0.629852
Adj. R-squared	0.444780	0.045816	0.617445
Sum sq. resids	0.470033	0.713615	0.069482
S.E. equation	0.051243	0.063140	0.019702
F-statistic	25.70020	2.480478	50.76514
Log likelihood	292.2824	253.4512	470.0743
Akaike AIC	-3.067552	-2.650012	-4.979294
Schwarz SC	-2.946153	-2.528613	-4.857895
Mean dependent	-0.006001	0.000987	-0.010211
S.D. dependent	0.068771	0.064638	0.031854

VAR III – LAG 1-3

Sample (adjusted): 2002M05 2017M09
Included observations: 185 after adjustments

	DLNIPCA	DLNPRODIND	DLNJRIGPM
DLNIPCA(-1)	0.611429	-0.008431	0.028449
	(0.07604)	(0.09339)	(0.02927)
	[8.04107]***	[-0.09028]	[0.97205]
DLNIPCA(-2)	0.039023	-0.000955	0.053152
	(0.08963)	(0.11008)	(0.03450)
	[0.43538]	[-0.00867]	[1.54067]

VAR IV – LAG 1-1

Sample (adjusted): 2002M03 2017M09
Included observations: 187 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.605878	0.062932	-0.028695
	(0.05906)	(0.02331)	(0.01994)
	[10.2585]***	[2.69954]***	[-1.43898]
DLNJRIGPM(-1)	0.345635	0.728745	-0.093102
	(0.12981)	(0.05124)	(0.04383)
	[2.66259]**	[14.2226]***	[-2.12418]*

DLNIPCA(-3)	-0.100338	-0.037641	-0.015759
	(0.07655)	(0.09402)	(0.02946)
	[-1.31072]	[-0.40036]	[-0.53484]
DLNPRODIND(-1)	0.033302	-0.166411	-0.037911
	(0.06092)	(0.07482)	(0.02345)
	[0.54669]	[-2.22428]**	[-1.61692]
DLNPRODIND(-2)	0.012024	0.141308	0.042163
	(0.06116)	(0.07512)	(0.02354)
	[0.19659]	[1.88107]*	[1.79093]*
DLNPRODIND(-3)	-0.028711	-0.119331	0.035870
	(0.06150)	(0.07553)	(0.02367)
	[-0.46687]	[-1.57991]	[1.51536]
DLNJRIGPM(-1)	0.328980	0.110615	0.630965
	(0.19629)	(0.24108)	(0.07555)
	[1.67596]*	[0.45883]	[8.35119]***
DLNJRIGPM(-2)	0.293049	-0.452775	0.162548
	(0.23386)	(0.28722)	(0.09001)
	[1.25310]	[-1.57640]	[1.80583]*
DLNJRIGPM(-3)	-0.227436	0.264103	-0.029697
	(0.20146)	(0.24743)	(0.07754)
	[-1.12894]	[1.06740]	[-0.38298]
C	0.001104	2.31E-05	-0.002414
	(0.00400)	(0.00492)	(0.00154)
	[0.27584]	[0.00469]	[-1.56632]
R-squared	0.471773	0.098555	0.635416
Adj. R-squared	0.444607	0.052195	0.616666
Sum sq. resids	0.461484	0.696107	0.068368
S.E. equation	0.051352	0.063069	0.019766
F-statistic	17.36635	2.125868	33.88877

DLNM1(-1)	0.142735	-0.043411	-0.121617
	(0.21348)	(0.08426)	(0.07208)
	[0.66862]	[-0.51519]	[-1.68727]
C	6.72E-05	-0.002396	0.008049
	(0.00424)	(0.00167)	(0.00143)
	[0.01585]	[-1.43224]	[5.62437]***
R-squared	0.459517	0.606930	0.062428
Adj. R-squared	0.450657	0.600486	0.047058
Sum sq. resids	0.473626	0.073791	0.053994
S.E. equation	0.050874	0.020081	0.017177
F-statistic	51.86207	94.18874	4.061655
Log likelihood	293.6433	467.4773	496.6821
Akaike AIC	-3.097789	-4.956976	-5.269327
Schwarz SC	-3.028674	-4.887861	-5.200213
Mean dependent	-0.005804	-0.010232	0.008137
S.D. dependent	0.068639	0.031769	0.017596

Log likelihood	291.9103	253.8875	468.5424
Akaike AIC	-3.047679	-2.636622	-4.957215
Schwarz SC	-2.873605	-2.462549	-4.783141
Mean dependent	-0.006196	0.000841	-0.010136
S.D. dependent	0.068906	0.064783	0.031924

VAR IV – LAG 1-2

Sample (adjusted): 2002M04 2017M09
Included observations: 186 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.607498	0.027418	-0.034048
	(0.07568)	(0.02958)	(0.02510)
	[8.02764]***	[0.92688]	[-1.35655]
DLNIPCA(-2)	-0.018600	0.047830	0.019169
	(0.07674)	(0.03000)	(0.02545)
	[-0.24238]	[1.59454]	[0.75319]
DLNJRIGPM(-1)	0.229681	0.624675	-0.018210
	(0.19052)	(0.07447)	(0.06319)
	[1.20552]	[8.38783]***	[-0.28818]
DLNJRIGPM(-2)	0.195236	0.134211	-0.105815
	(0.19639)	(0.07677)	(0.06514)
	[0.99411]	[1.74827]*	[-1.62454]
DLNM1(-1)	0.207260	0.014316	-0.123322
	(0.22319)	(0.08724)	(0.07402)
	[0.92862]	[0.16410]	[-1.66599]*
DLNM1(-2)	0.199107	0.082797	0.144061
	(0.21775)	(0.08512)	(0.07222)
	[0.91437]	[0.97273]	[1.99474]**
C	-0.001730	-0.003228	0.006572

VAR IV – LAG 1-3

Sample (adjusted): 2002M05 2017M09
Included observations: 185 after adjustments

	DLNIPCA	DLNJRIGPM	DLNM1
DLNIPCA(-1)	0.598510	0.025544	-0.037618
	(0.07573)	(0.02983)	(0.02502)
	[7.90326]***	[0.85630]	[-1.50366]
DLNIPCA(-2)	0.040945	0.053675	0.030002
	(0.08948)	(0.03525)	(0.02956)
	[0.45757]	[1.52280]	[1.01492]
DLNIPCA(-3)	-0.081469	-0.008099	-0.009708
	(0.07706)	(0.03036)	(0.02546)
	[-1.05718]	[-0.26681]	[-0.38134]
DLNJRIGPM(-1)	0.269742	0.622049	0.000404
	(0.19390)	(0.07638)	(0.06406)
	[1.39113]	[8.14421]***	[0.00631]
DLNJRIGPM(-2)	0.347854	0.150410	-0.057538
	(0.23083)	(0.09093)	(0.07626)
	[1.50697]	[1.65421]*	[-0.75454]
DLNJRIGPM(-3)	-0.183246	-0.004065	-0.080176
	(0.20536)	(0.08089)	(0.06784)
	[-0.89230]	[-0.05025]	[-1.18178]
DLNM1(-1)	0.129895	0.002471	-0.158683

	(0.00468)	(0.00183)	(0.00155)
	[-0.36991]	[-1.76617]*	[4.23744]***
R-squared	0.466170	0.619810	0.099445
Adj. R-squared	0.448276	0.607066	0.069259
Sum sq. resids	0.467074	0.071367	0.051377
S.E. equation	0.051082	0.019967	0.016942
F-statistic	26.05211	48.63624	3.294386
Log likelihood	292.8698	467.5848	498.1480
Akaike AIC	-3.073869	-4.952525	-5.281161
Schwarz SC	-2.952470	-4.831126	-5.159762
Mean dependent	-0.006001	-0.010211	0.008012
S.D. dependent	0.068771	0.031854	0.017561

	(0.22769)	(0.08969)	(0.07522)
	[0.57048]	[0.02755]	[-2.10959]**
DLNM1(-2)	0.165259	0.090467	0.129099
	(0.22517)	(0.08870)	(0.07439)
	[0.73392]	[1.01996]	[1.73551]*
DLNM1(-3)	0.370472	0.122588	0.061268
	(0.22005)	(0.08668)	(0.07270)
	[1.68354]*	[1.41425]	[0.84280]
C	-0.003958	-0.004072	0.006161
	(0.00497)	(0.00196)	(0.00164)
	[-0.79598]	[-2.07881]**	[3.75085]***
R-squared	0.481198	0.624969	0.119312
Adj. R-squared	0.454517	0.605682	0.074020
Sum sq. resids	0.453250	0.070327	0.049465
S.E. equation	0.050892	0.020047	0.016812
F-statistic	18.03509	32.40318	2.634262
Log likelihood	293.5756	465.9292	498.4788
Akaike AIC	-3.065682	-4.928965	-5.280852
Schwarz SC	-2.891609	-4.754891	-5.106779
Mean dependent	-0.006196	-0.010136	0.007852
S.D. dependent	0.068906	0.031924	0.017472

Nota: Foram utilizadas 178 observações depois dos ajustamentos. Os desvios-padrão encontram-se em ( ) e t-estatístico em [ ].
Fonte: O autor, 2019.