



UNIVERSIDADE FEDERAL DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA – CAEN
MESTRADO PROFISSIONAL EM ECONOMIA

VITOR HUGO GASPAR PINTO

**MECANISMOS DE PREVISÃO DA ATIVIDADE ECONÔMICA BRASILEIRA EM
CENÁRIOS DISTINTOS DE VOLATILIDADE**

FORTALEZA
2017

VITOR HUGO GASPAR PINTO

MECANISMOS DE PREVISÃO DA ATIVIDADE ECONÔMICA BRASILEIRA EM
CENÁRIOS DISTINTOS DE VOLATILIDADE

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Economia da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Economia. Área de concentração: Econometria Aplicada

Orientador: Prof. Dr. Paulo de Melo Jorge Neto

FORTALEZA
2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

G232m Gaspar Pinto, Vitor Hugo.
MECANISMOS DE PREVISÃO DA ATIVIDADE ECONÔMICA BRMECANISMOS DE PREVISÃO
DA ATIVIDADE ECONÔMICA BRASILEIRA EM CENÁRIOS DISTINTOS DE
VOLATILIDADEASILEIRA EM CENÁRIOS DISTINTOS DE VOLATILIDADE / Vitor Hugo Gaspar
Pinto. – 2017.
37 f.

Dissertação (mestrado) – Universidade Federal do Ceará, Faculdade de Economia, Administração,
Atuária e Contabilidade, Mestrado Profissional em Economia do Setor Público, Fortaleza, 2017.
Orientação: Prof. Dr. Paulo de Melo Jorge Neto.
Coorientação: Prof. Dr. Elano Ferreira Arruda.

1. Atividade Econômica. 2. ARMA. 3. VAR. I. Título.

CDD 330

VÍTOR HUGO GASPAR PINTO

MECANISMOS DE PREVISÃO DA ATIVIDADE ECONÔMICA BRASILEIRA EM
CENÁRIOS DISTINTOS DE VOLATILIDADE

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Economia da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Economia. Área de concentração: Econometria Aplicada

Orientador: Prof. Dr. Paulo de Melo Jorge Neto

Aprovada em ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Paulo de Melo Jorge Neto (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Elano Ferreira Arruda (Membro)
Universidade Federal do Ceará (UFC)

Prof. Dr. Glauber Marques Nojosa (Membro)
Universidade Federal do Ceará (UFC)

RESUMO

O presente estudo tem como objetivo realizar previsões para a atividade econômica, ou crescimento do Produto Interno Bruto (PIB) do Brasil, utilizando modelos AR, ARMA e VAR com dados mensais entre janeiro de 2002 e dezembro de 2016 e considerando ambientes de distintos de volatilidade. Os resultados apontam que a volatilidade é importante para explicar a habilidade dos modelos econométricos, dado que os erros de previsão se mostraram maiores em cenários de maior instabilidade. Em termos comparativos, não há diferença estatisticamente significativa entre as habilidades preditivas dos melhores modelos no ambiente de menor volatilidade e o modelo VAR(2) se destacou por apresentar os melhores prognósticos em situações de maior instabilidade.

Palavras-Chave: Atividade Econômica, ARMA, VAR.

ABSTRACT

This paper aims to forecast the economic activity or growth of Brazil's Gross Domestic Product (GDP) using AR, ARMA and VAR models with monthly data between January 2002 and December 2016 and considering different volatility environments. The results indicate that volatility is important to explain the ability of econometric models, since the prediction errors were larger in scenarios of greater instability. In comparative terms, there is no statistically significant difference between the predictive abilities of the best models in the environment of lower volatility and the VAR model (2) was distinguished by presenting the best prognostics in situations of greater instability.

KeyWords: Economic Activity, ARMA, VAR.

SUMÁRIO

1. INTRODUÇÃO	8
2. REFERENCIAL TEÓRICO	10
2.1 Previsão do PIB	10
2.2 Volatilidade de Desempenho do PIB.....	12
2.3 Literatura de Previsão em Economia.....	13
3. MÉTODOS E ANÁLISE DOS DADOS	15
3.1 – Modelos de previsão ARMA	16
3.2 – Modelos de Previsão VAR	18
3.3 – Avaliando as Previsões	20
4. RESULTADOS E DISCUSSÃO	22
4.1. Análise dos Resultados dos Modelos Autoregressivos (AR)	23
4.2. Análise dos Resultados dos Modelos Autoregressivos com Média Móvel (ARMA) ...	24
4.3. Análise dos Resultados dos Modelos Vetoriais Autoregressivos (VAR).....	25
4.4. Análise Comparativa dos Resultados	26
5. CONSIDERAÇÕES FINAIS	28
REFERÊNCIAS BIBLIOGRÁFICAS	30
APÊNDICE.....	32

1. INTRODUÇÃO

O Produto Interno Bruto (PIB) é calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e representa a soma de todos os bens e serviços produzidos por uma economia em certo período de tempo. É considerado o principal indicador do nível de atividade econômica, pois o seu crescimento significa que o país está gerando mais empregos e renda.

O cálculo do PIB revela não só o crescimento total da economia, mas também de forma setorial como cada área vem se comportando, podendo então destacar as áreas mais eficientes e mais deficitárias, contribuindo para a formação de estratégias de governo e mercado.

Além do desempenho dos setores da economia, outros fatores também influenciam no comportamento passado e futuro do PIB, onde podem ser destacados os investimentos públicos e privados, gastos públicos, comércio externo, política fiscal, inflação, instabilidade política, política monetária, entre outros. Os setores da economia e outros fatores acima citados se interligam e interferem entre si, sendo então determinantes para explicar o comportamento futuro da atividade econômica.

Portanto, a produção de previsões acuradas para a atividade econômica se mostra fundamental para garantir credibilidade e horizonte de previsão para os investidores em relação à economia e para orientar os gestores públicos em relação às possíveis frustrações de receitas (quando se espera maior crescimento da economia e, portanto, maior arrecadação tributária, e não ocorre), e sobre descolamento dos gastos/investimentos públicos de uma situação de saúde fiscal.

Por outro lado, como destacam Stock e Watson (2007), a previsão de variáveis macroeconômicas precisa considerar aspectos conjunturais, uma vez que os modelos econômicos aplicados e de séries temporais ganham em importância na obtenção de previsões acuradas em cenários de maior volatilidade; ou seja, os autores indicam que, quanto mais instável for o ambiente econômico, mais complicado é o processo de previsão econômica e, conseqüentemente, maior o desafio do gestor público na produção de previsões eficientes.

Diante disso, o presente estudo tem como objetivo realizar previsões para a atividade econômica, ou crescimento do PIB do Brasil, utilizando modelos macroeconômicos, via modelos vetoriais autoregressivos (VAR), e técnicas de séries temporais com dados mensais entre janeiro de 2002 e dezembro de 2016. De modo a incorporar cenários distintos de volatilidade, analisou-se inicialmente a evolução da volatilidade do PIB que indicou o ano de

2014 como o menos volátil. Portanto, a estratégia econométrica consistirá em dois exercícios, quais sejam, a estimação de modelos com dados mensais de janeiro de 2002 a dezembro de 2013 com previsões para o ano de 2014 (cenário de menor volatilidade), e exercícios semelhantes com informações entre janeiro de 2002 a dezembro de 2015 e previsão para 2016 (cenário de maior volatilidade). A hipótese desse estudo, na linha de Stock e Watson (2007), é a de que modelos de previsão são mais eficientes, ou geram previsões com menores erros, em cenários de baixa volatilidade.

Vale destacar que, como afirma Patterson (2001), se o objetivo da análise econométrica é realizar previsões, os modelos não devem ser selecionados simplesmente por seu bom ajustamento, mas por sua eficiência preditiva; isto é, o melhor modelo é aquele que gera previsões com menor erro de previsão. Portanto, neste estudo, os mecanismos preditivos serão selecionados pelo critério da raiz do erro quadrático médio de previsão (REQM) e, adicionalmente, utilizar-se-á o teste de Diebold e Mariano (1995) para examinar se a diferença no desempenho preditivo dos melhores modelos é estatisticamente significativa. Além disso, à guisa de comparação, os resultados dos modelos econométricos serão comparados aos do Índice de Atividade Econômica do Banco Central do Brasil (IBC-Br), considerado o principal indicador antecedente do PIB.

Além dessa introdução, esse trabalho possui mais quatro seções. A seção seguinte se reserva a apresentar uma revisão de literatura sobre PIB, volatilidade e previsão. A seção três descreve as técnicas econométricas empregadas no estudo. Em seguida os resultados são apresentados e discutidos. Por fim, são tecidas as considerações finais do estudo.

2. REFERENCIAL TEÓRICO

2.1 Previsão do PIB

O Produto Interno Bruto é o principal medidor do crescimento econômico de uma região, seja ela uma cidade, um estado, um país ou mesmo um grupo de nações. Seu cálculo é feito a partir da soma do valor de todos os serviços e bens produzidos na região escolhida em um período determinado.

A medição do PIB começou a ser realizada em nível mundial em 1948, tendo seu conceito espalhado pelo Fundo Monetário Internacional - FMI. No Brasil vinha sendo medido pela Faculdade Getúlio Vargas até 1990, sendo em seguida medido pelo Instituto Brasileiro de Geografia e Estatística - IBGE.

A elaboração de previsões sobre a trajetória futura do PIB constitui uma das ocupações principais dos economistas. Essa análise possui papel central na tomada de decisões dos agentes econômicos e políticos, dado que o crescimento do PIB influi em praticamente todos os setores da economia e sociais, dentro e fora do país.

Segundo Cavalcanti (2003), as expectativas de mercado desempenham um papel importante na economia fornecendo subsídio para as decisões de política monetária, sendo esse um instrumento importante para o planejamento das ações de curto, médio e longo prazos dos formuladores de política econômica e dos investidores.

A literatura sobre previsão do PIB apresentou grandes avanços nas últimas décadas, sugerindo técnicas e diversos índices agregando diferentes óticas de análises e métodos de antecipação do PIB oficial divulgado trimestralmente pelo IBGE.

De acordo com o Banco Central do Brasil - BACEN (2015) as projeções, em muitos casos com o auxílio de modelagem econométrica, são realizadas para variáveis relacionadas à atividade econômica, às taxas de juros e de câmbio, à variação dos índices de preços, ao balanço de pagamentos e ao setor fiscal da economia brasileira.

Criado pelo Banco Central do Brasil, com dados que retroagem a 2003 e periodicidade mensal, o IBC-Br é considerado pelo mercado financeiro um dos mais importantes indicadores de previsão do PIB. O IBC-Br é considerado um parâmetro preliminar da evolução da atividade econômica brasileira, sendo criado inicialmente para auxiliar a definição da meta da taxa básica de juros.

Em seu cálculo o IBC-Br incorpora estimativas de crescimento do setor agropecuário, industrial, serviços, acrescidos dos impostos sobre produtos, estimados a partir da evolução da oferta total (produção + importações). Além de ser um índice nacional, ele também se encontra segmentado por Estados e Regiões.

Apesar de ser considerado um previsor do PIB, o IBC-Br, por ter metodologia de cálculo diferente do PIB, também é avaliado como um indicador próprio de comportamento da atividade econômica, ou seja, uma forma paralela ao PIB de se avaliar o desempenho da economia.

2.2 Volatilidade de Desempenho do PIB

Enquanto algumas economias desfrutam de um ritmo constante/consistente de crescimento ou estabilidade, outras apresentam grandes oscilações, com picos de crescimento elevado e decréscimos acentuados em um curto ou médio período.

É fato notório que um crescimento do PIB é uma boa notícia para o mercado e uma redução pode ser considerada uma certa frustração. Porém, o verdadeiro sentido de se calcular o PIB está na observação do seu comportamento durante os anos, pois assim podemos analisar a sua evolução e impacto futuro nos diferentes agentes econômicos

Alguns estudos vêm sendo feitos no sentido de identificar os impactos dessas oscilações/volatilidade sobre o PIB, como Ramey e Ramey (1995) e Martin e Rogers (1997), para os países da OCDE, que encontraram evidências de uma correlação negativa entre a volatilidade dos ciclos de econômicos e o crescimento do PIB; ou seja, a instabilidade econômica em curto prazo afetaria o ambiente de projeção dos agentes econômicos e, conseqüentemente, o crescimento de longo prazo.

Ao analisar série americana de PNB de 1903 a 1981, Zarnowitz e Moore (1986) notaram que a alta volatilidade está associada a períodos de baixo crescimento. Aizenman e Marion (1993) obtém evidências na mesma linha ao identificar uma ligação negativa entre incerteza política e crescimento econômico, através de modelos AR(1) aplicados sobre diversos instrumentos de política.

Conforme demonstrado por Federer (1996), tanto mudanças no nível de preços como nos padrões de volatilidade dos preços do petróleo tem impacto negativo no crescimento econômico. O autor conclui que a volatilidade tem impacto negativo no crescimento econômico e que mudanças no preço demoram cerca de um ano para repercutir sobre o crescimento.

De acordo com Bressan e Lima (2002), é importante considerar cenários distintos de volatilidade quando da realização de projeções, planejamento e avaliação das políticas econômicas.

2.3 Literatura de Previsão em Economia

A literatura econômica tem sido amplamente utilizada para previsão de variáveis econômicas. Nesse sentido, por meio de modelos econométricos, diversos autores nacionais e internacionais realizam prognósticos de crescimento econômico, inflação, taxa de juros, câmbio, entre outros.

Cicarelli e Rebucci (2003) demonstram a reação do sistema monetário sob choque de política monetária em quatro bancos centrais europeus, utilizando-se de aplicações dos métodos bayesianos de Litterman para estimação dos parâmetros do VAR. Concluem que modelos VAR apresentam bom desempenho preditivo frente aos tradicionais modelos de equações simultâneas.

Tatiwa, Bierens e Castelar (2005) realizam previsões do PIB trimestral brasileiro a partir de modelos de séries temporais e modelos de fatores lineares e não lineares. Os autores destacam o bom desempenho de previsão dos modelos ARMA, mas apontam que os modelos de fatores (por agregarem mais informação) e os modelos não lineares (que incorporam cenários de instabilidade) se mostram mais eficientes.

Arruda, Ferreira e Castelar (2011) utilizam modelos lineares e não lineares de séries temporais e da curva de Phillips para prever a inflação no Brasil. Os autores concluem que os modelos de séries temporais apresentam se mostram eficientes, com destaque para o modelo VAR; todavia, modelos não lineares da curva de Phillips se destacaram por produzir previsões com menores erros.

Com vistas a produzir prognósticos para o PIB agrícola do Brasil, Tatiwa, Oliveira Júnior e Castelar (2012), utilizam modelos econométricos ARMA e modelos lineares e não lineares de Índice de Difusão. Os resultados de eficiência preditiva apontam para uma superioridade das previsões geradas pelos modelos de Índice de Difusão (que contém mais informação) sobre os modelos ARMA. Entre os modelos de Índice de Difusão, o modelo não linear com efeito *threshold* apresentou o melhor desempenho; ou seja, aquele que incorpora mais informação e considera possíveis momentos de instabilidade.

De acordo com o Relatório de Inflação de 2008 do Banco Central (2008), essa instituição utiliza os modelos VAR como instrumento de previsão da inflação. Além de pontuar o bom desempenho desse modelo econométrico preditivo para o curto e médio prazo, ainda destaca a utilização do método em outros bancos centrais, como segue:

Finalmente, cabe notar que análises de erros de previsão feitas com dados em tempo real indicam que os modelos VAR têm seu melhor desempenho no curto e médio prazo (intervalo de até um ano) e, com frequência, superam a performance de modelos estruturais. Vale notar que o bom desempenho dos modelos VAR em prever a inflação no curto e médio prazo não constitui particularidade da economia brasileira, haja vista que resultados similares têm sido identificados para outros bancos centrais, como pode ser visto, por exemplo, em Altig, Carlstrom, Lansing (1995) e Sims (2002) para o caso norte-americano e Adolfson et al. (2005) para o caso sueco. (BACEN 2008)

Nos Estados Unidos Koop e Korobilis (2013) obtêm bons resultados preditivos utilizando dados trimestrais no modelo VAR com parâmetros variáveis no tempo e 25 variáveis endógenas para prever inflação, produto real e taxa de juros.


Kapetanios, Labhard e Price (2008) realizam testes comparativos dos modelos de previsão passeio aleatório (*random walk*), AR com constante, modelo de média incondicional, VAR, BVAR, Modelo Markov-Switching e modelo auto-regressivo *smooth-transition* (STAR) para gerar previsões para inflação e produto. Os resultados indicam que os modelos VAR/BVAR se mostram mais eficazes.

3. MÉTODOS E ANÁLISE DOS DADOS

Nesta seção serão descritas as técnicas e os modelos econométricos utilizados na geração das previsões, além de uma descrição e análise das propriedades das séries empregadas em cada modelo. O presente trabalho utiliza como indicador de atividade econômica a variação do Produto Interno Bruto (PIB) mensal, estimado e disponibilizado pelo Banco Central do Brasil (BACEN), entre janeiro de 2002 e dezembro de 2016. Vale destacar que esse indicador foi devidamente deflacionado pelo índice geral de preços – disponibilidade interna – IGP-DI – disponibilizado pela fundação Getúlio Vargas. É importante ressaltar que essa variável não é a medida oficial do PIB, dado que a menor frequência desse indicador oficial é trimestral, todavia é um importante indicador de acompanhamento da atividade econômica, que é o objeto de previsão desse estudo.

De modo a considerar cenários distintos de volatilidade, analisou-se inicialmente a evolução do desvio padrão desse indicador que se encontra descrita no gráfico 1. A análise do gráfico indica que o ano de 2014 foi o período em que a atividade econômica apresentou a menor volatilidade. Portanto, serão estimados blocos de modelos para uma amostra entre janeiro de 2002 e dezembro de 2013 com previsões para o ano de 2014 (menor volatilidade) e para a amostra completa entre janeiro de 2002 e dezembro de 2015 com previsões para o ano de 2016 (volatilidade superior à de 2014). A eficiência preditiva dos modelos será aferida pela raiz do erro quadrático médio de previsão (REQM).

Gráfico 1: Evolução da Volatilidade Mensal da Atividade Econômica do Brasil



Fonte: Elaboração Própria

3.1 – Modelos de previsão ARMA

Os estudos sobre previsão de variáveis econômicas predominantes entre 1960 e 1970 eram baseados em modelos de equações simultâneas, estrutura que mudaria devido aos choques do petróleo ocorridos na década de 1970 e à crítica de Lucas (1976) segundo a qual os parâmetros econômicos reais dependiam da política econômica vigente, não sendo, portanto, fixos diante de alterações nos cenários econômicos.

Box e Jenkins (1970) propõem uma análise que abriu caminho para uma nova geração de técnicas de previsão. A ideia era estimar um modelo que pudesse ser analisado como tendo sido gerado pelos próprios dados amostrais; ou seja, essa técnica permitiu que os prognósticos futuros das variáveis econômicas fossem realizados tomando por base apenas seus valores presentes e passados, substituindo a ênfase dada aos modelos de equações simultâneas pela análise das propriedades estocásticas em uma série temporal.

Assim, os modelos autoregressivos de média móvel (ARMA) começaram a ser amplamente utilizados para realizar previsões nas mais diversas áreas da economia. Em virtude da sua simplicidade e da qualidade de suas previsões, esses modelos univariados são usualmente utilizados como *benchmarks* para outros modelos, como em Stock e Watson (2007) e Arruda, Ferreira e Castelar (2011).

Nos moldes de Hamilton (1994), um modelo ARMA (p, q) tem a seguinte forma:

$$y_t = \mu + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (1)$$

Em que o índice p refere-se ao número de defasagens da própria variável dependente ($y_t, y_{t-1}, y_{t-2}, \dots, y_{t-p}$), e q refere-se ao número de defasagens dos choques exógenos ou termos de erro ($\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-p}$). E, ainda, ε_t é $iid \sim N(0, \sigma^2)$.

Caso a regressão contenha apenas o aspecto autoregressivo, ou seja: $\theta_1 = \theta_2 = \dots = \theta_p = 0$, ele pode ser estimado por mínimos quadrados ordinários. Caso contrário, não é possível expressar a soma dos quadrados dos erros simplesmente como função dos y 's observados e dos parâmetros do modelo autorregressivo, logo deve-se utilizar o método de máxima verossimilhança.

Se o crescimento do PIB apresentar uma relação linear com seus valores passados, que capturam a persistência da atividade econômica ou duração do ciclo econômico, e com valores correntes e passados de choques aleatórios, então um modelo ARMA será um bom mecanismo gerador de previsões. Nesse estudo, para gerar previsões para o crescimento do PIB do Brasil, foram utilizados até seis defasagens nos modelos ARMA (p,q). Os melhores modelos foram selecionados pelo seu desempenho preditivo; ou seja, resultados com menores REQM de previsão.

3.2 – Modelos de Previsão VAR

Os modelos vetoriais autorregressivos (VAR), originalmente apresentados por Sims (1980), ganharam força na década de 1980, por se mostrarem superiores aos modelos de equações simultâneas em termos de eficiência preditiva.

As relações macroeconômicas geralmente são sistêmicas, no sentido de que se precisa de várias equações para se promover uma análise de conjuntura mais acurada. Portanto, o uso de modelos univariados, como os dos modelos ARMA apresentados anteriormente, podem ser limitados para expressar relações econômicas. Dessa forma, Stock e Watson (1996 e 1999) afirmam a importância de que, em análises que envolvam previsão de variáveis como o crescimento do PIB, seja considerado a possibilidade de que outras variáveis econômicas, tais como oferta de crédito (indicativa da política monetária), inflação (que aponta para as condições de oferta da economia) e um indicador de política fiscal (como o resultado primário, por exemplo), contenham informações adicionais relevantes que possam contribuir para a previsão da atividade econômica.

Ainda nesse sentido, Caiado (2002) afirma que esses modelos podem ser utilizados em alternativa ao método de modelos ARMA, uma vez que levam em consideração a existência de relações interdependentes entre as variáveis e permitem a avaliação do impacto dinâmico das perturbações aleatórias sobre o sistema de variáveis, o que os tornam particularmente úteis e eficientes na previsão do comportamento futuro de séries temporais inter-relacionadas. Por essas razões, torna-se importante investigar se modelos VAR produzem resultados mais robustos em termos de eficiência preditiva do que modelos ARMA univariados.

Segundo Hamilton (1994), um vetor auto regressivo de ordem p , VAR (p), é a forma reduzida de um modelo dinâmico de equações simultâneas e pode ser expresso como:

$$y_t = c + \sum_{i=1}^p \Phi_i y_{t-i} + \varepsilon_t \quad (2)$$

No qual, y_t representa um vetor ($n \times 1$) com valores das n variáveis incluídas no modelo e ε_t é $iid \sim N(0, \Sigma)$.

Neste trabalho, serão empregadas até seis defasagens de um modelo VAR nos moldes tradicionais para análise macroeconômica, qual seja, um modelo VAR com as variáveis: i) taxa de crescimento do PIB (GPIB), variável a ser prevista; ii) a inflação, medida pelo índice de preços ao consumidor amplo (IPCA), como indicador das condições de oferta; iii) o resultado

primário (PRIM), como indicador de política fiscal, disponibilizado pelo Banco Central do Brasil (BACEN) e iv) a taxa de variação do agregado monetário M1, também disponibilizado BACEN (GM1). Todas as variáveis expressas em termos monetários foram devidamente deflacionadas pelo IGP-DI. Os gráficos 2 a 5, em apêndice, apresentam a evolução desses indicadores.

A tabela 1 apresenta o resultado dos testes de raiz unitária de Dickey-Fuller aumentado (ADF) e de Kwiatkowski, Phillips, Schmidt e Shin (KPSS). O primeiro tem a presença de raiz unitária como hipótese nula enquanto o último tem a estacionariedade como hipótese a ser testada. Todas as variáveis aqui empregadas se mostraram estacionárias ambos os testes. A variável de oferta de crédito (M1) foi incluída em termos de taxa de crescimento porque se mostrou estacionária apenas em primeira diferença, ou seja, ela é integrada de ordem 1, I(1).

Tabela 1: Resultados dos Testes de Raiz Unitária modelos VAR

VARIÁVEL	ADF	KPSS
GPIB	-3,49 (-2,87)	0,11 (0,46)
GM1	-7,31 (-2,87)	0,13 (0,46)
PRIM	-3,40 (-2,87)	0,71 (0,74)*
IPCA	-5,36 (-2,87)	0,20 (0,46)

Fonte: Elaboração Própria a partir dos resultados obtidos. Valor crítico do teste a 5% de significância entre parêntesis. * Valor Crítico do teste KPSS a 1%.

3.3 – Avaliando as Previsões


Para avaliar a eficiência preditiva dos modelos econômicos e de series temporais, deve-se considerar algum critério para decidir sobre que modelo se mostra mais adequado ou mais eficiente nesse objetivo. Se o propósito da análise econômica é a realização de prognósticos futuros, os modelos ou técnicas empregadas não devem ser considerados apenas por seu “bom ajustamento”, mas sobretudo pela qualidade de suas previsões; isto é, nessas condições, o modelo mais adequado é aquele que erra menos em suas previsões (PATTERSON, 2001). Um dos critérios mais utilizados para se comparar previsões é a raiz do erro quadrático médio de previsão (REQM), dada por:

$$REQM = \sqrt{\frac{\sum_{t=T+1}^{T+h} (Y_t^F - Y_t)^2}{h}} \quad (3)$$

Onde Y_t^F e Y_t representam, respectivamente, o valor previsto e o valor realizado da variável Y , e h indica o número de períodos do horizonte de previsão.

West (2006) apresenta um diagrama ilustrativo do procedimento usual de previsão em econometria, conforme figura 1. Portanto, a amostra total empregada nesse estudo contém informações mensais entre janeiro de 2002 e dezembro de 2016 ($T+1$ no diagrama). Todos os modelos serão estimados utilizando dados de janeiro de 2002 a dezembro de 2015 (R observações no diagrama). E, por fim, serão geradas previsões para o período de janeiro a dezembro de 2016 (P resultados de previsão no diagrama). De modo a verificar o desempenho preditivos desses modelos em cenários de menor volatilidade, empregou-se o mesmo método para fazer previsões entre janeiro e dezembro de 2014, ano em que a atividade econômica apresentou a menor volatilidade (nesse caso os modelos foram estimados com dados entre janeiro de 2002 a dezembro de 2013).

Figura 1: Diagrama de Previsão



Fonte: West (2006)

Uma vez geradas as previsões, calculam-se os REQM de cada modelo e selecionam-se

aqueles que apresentaram maior eficiência preditiva; ou seja, menores REQM de previsão.

Após a identificação dos modelos de melhor performance preditiva, empregar-se-á o critério estatístico de Diebold e Mariano (1995) para comparação de previsões, descrito a seguir. Seja duas sequências de valores previstos $\{\hat{Y}_{it}\}_{t=1}^T$ e $\{\hat{Y}_{jt}\}_{t=1}^T$, da variável econômica $\{Y_t\}_{t=1}^T$. Sejam $\{e_{it}\}_{t=1}^T$ e $\{e_{jt}\}_{t=1}^T$ seus respectivos erros de previsão. O teste de consiste em uma análise das perdas associadas a cada uma dessas previsões a partir de um critério métrico estatístico que avalia a igualdade de seus desempenhos preditivos. Essa investigação parte de uma função de perda, expressa por $g(Y_t, \hat{Y}_{it}) = g(e_{it})$ e $(Y_t, \hat{Y}_{jt}) = g(e_{jt})$, que mede o erro de previsão, ou seja, é calculada a partir dos valores realizados e previstos da variável em questão. No presente estudo, essa função será o REQM de previsão dos modelos. Os autores sugerem a estatística de teste a seguir¹:

$$S_1 = \frac{\bar{d}}{\sqrt{\frac{2\pi f_d(0)}{T}}} \quad (4)$$

Testa-se a hipótese nula em que $E[g(e_{it})] = E[g(e_{jt})]$, ou, ainda, que $E[d_t] = 0$.

¹Onde : $d = g(e_{it}) - g(e_{jt})$, é a perda diferencial; $\bar{d} = \frac{1}{T} = \sum_{t=1}^T [g(e_{it}) - g(e_{jt})]$;

$f_d(0) = \frac{1}{2\pi} \sum_{\tau=-\infty}^{\infty} \gamma_d(\tau)$, $\hat{f}_d(0)$ é um estimador consistente de $f_d(0)$; $\gamma_d(\tau) = E[(d_t - \mu)(d_{t\tau} - \mu)]$ e $\sqrt{T}(\bar{d} - \mu) \xrightarrow{d} N(0, 2\pi f_d(0))$.

4. RESULTADOS E DISCUSSÃO

Para analisar o desempenho preditivo dos modelos econométricos em diferentes ambientes de volatilidade da atividade econômica, serão estimados modelos entre janeiro de 2002 a dezembro de 2013, com previsão para 2014 (menor volatilidade), e uma análise semelhante é realizada entre janeiro de 2002 a dezembro de 2015 com previsões para 2016 (maior volatilidade).

Os resultados foram analisados a partir da REQM de previsão observada nos modelos econométricos AR, ARMA e VAR, até a sexta defasagem. Após essa investigação, os modelos que apresentarem a melhor eficiência preditiva, ou menor erro de previsão, serão selecionados e comparados a partir do teste de Diebold e Mariano (1995).

Por fim, à guisa de comparação dos resultados, esses modelos são comparados com as projeções geradas pelo IBC-Br, considerado prévia do PIB. Vale destacar que as informações que contribuem para a previsão da atividade econômica contidas no IBC-Br são revisadas mês a mês, utilizando informações sobre a conjuntura econômica atualizadas. Por outro lado, as previsões dos modelos aqui empregados são obtidas através de um método de estimação fixo, no qual os parâmetros são estimados para um dado período (por exemplo, janeiro de 2002 e dezembro de 2015) e as previsões são geradas para o ano seguinte (janeiro de 2016 e dezembro 2016), mantidos os coeficientes estimados iniciais; ou seja, sem atualizações. Portanto, essa comparação deve ser vista com cautela, dadas as peculiaridades e vantagens informacionais do IBC-Br.

4.1. Análise dos Resultados dos Modelos Autoregressivos (AR)

Para selecionar mecanismos preditivos para a atividade econômica, inicialmente utilizou-se até seis defasagens de modelos autorregressivos (ARs) e as previsões foram realizadas para 2014 e 2016. A eficiência preditiva dos modelos é medida pela REQM de previsão. Os resultados estão sintetizados na tabela 2.

Tabela 2: Resultados dos modelos Autorregressivos – AR(p)

Resultado/Modelos	AR(1)	AR(2)	AR(3)	AR(4)	AR(5)	AR(6)
REQM 2014	2,44	2,48	2,43	2,40	2,28	2,29
REQM 2016	3,36	3,29	3,25	3,27	3,14	3,11
Variação 2016/2014 (%)	-27,38	-24,62	-25,23	-26,60	-27,39	-26,37

Fonte: Elaboração Própria a partir dos resultados obtidos.

Em termos gerais, observa-se uma melhor qualidade das previsões geradas para o período de menor volatilidade; uma vez que, considerando modelos semelhantes, a REQM de previsão para o ano de 2014 foi menor em todos casos analisados, com REQMs, em média, 26,26% menores. Essa evidência indica que, quanto mais instável for o ambiente econômico, maior a dificuldade do gestor da política econômica para produzir prognósticos com erro reduzido (STOCK e WATSON, 2007). Os modelos mais eficientes do ponto de vista preditivo foram o AR(5), para 2014, e o AR(6), para 2016, com REQMs iguais a 2,28 e 3,11, respectivamente.

4.2. Análise dos Resultados dos Modelos Autorregressivos com Média Móvel (ARMA)

Após essa análise inicial, procedeu-se a investigação do desempenho de previsão dos modelos autorregressivos com média móvel. Como descrito anteriormente, foram utilizadas até seis defasagens desses modelos e os resultados estão sintetizados na tabela 3.

Tabela 3: Resultados dos modelos Autorregressivos com Média Móvel – ARMA(p,q)

Resultado/Modelos	ARMA (1,1)	ARMA (2,2)	ARMA (3,3)	ARMA (4,4)	ARMA (5,5)	ARMA (6,6)
REQM 2014	2,79	2,43	4,71	2,40	3,31	2,15
REQM 2016	3,61	3,34	3,43	4,59	3,84	2,65
Variação 2016/2014 (%)	-22,71	-27,24	37,32	-47,71	-13,80	-18,87

Fonte: Elaboração Própria a partir dos resultados obtidos.

Como nos modelos anteriores, observa-se uma melhor eficiência preditiva em ambientes de menor volatilidade com REQMs, em média, 15,5% menores para o ano de 2014. Apenas no modelo ARMA(3,3), a previsão para o ano de 2014 foi superior à de 2016. O modelo com melhor desempenho em 2014 foi o ARMA(6,6), com REQM 2,15; ou seja, um REQM 5,7% menor do que o melhor modelo AR do período, o AR(5). No ambiente mais volátil, em 2016, o ARMA(6,6) também se destacou com REQM de 2,65. Esse resultado é 14,79% melhor do que o modelo AR mais eficiente do período, o AR(6). Portanto, os melhores modelos ARMA, em termos gerais, apresentaram desempenho preditivo superior em relação aos ARs.

4.3. Análise dos Resultados dos Modelos Vetoriais Autoregressivos (VAR)

Por fim, procedeu-se uma análise semelhante considerando até seis defasagens do modelo VAR descrito na subseção 3.2. Os resultados estão sintetizados na tabela abaixo. Em todos os casos a previsão no ambiente mais volátil, ano de 2016, também apresentou erros de previsão superiores, confirmando a hipótese do trabalho e a indicação de Stock e Watson (2007), que destaca a dificuldade de geração de previsões acuradas em ambientes de instabilidade econômica. Em média, as REQMs foram 13,30% menores em 2014. Os melhores desempenhos foram observados nos modelos VAR(2) com REQMs de 2,24 e 2,50, respectivamente, para os anos de 2014 e 2016. E, ainda, é importante destacar que o maior conjunto de variáveis constantes nos modelos VAR parece contribuir para a qualidade de suas previsões em períodos de maior volatilidade, uma vez que tanto suas REQMs, como seu comparativo em relação ao ano de 2014, se mostram melhores frente aos modelos AR e ARMA.

Tabela 4: Resultados dos modelos Vetoriais Autoregressivos – VAR(p)

Resultado/Modelos	VAR(1)	VAR (2)	VAR (3)	VAR (4)	VAR (5)	VAR (6)
REQM 2014	2,50	2,24	2,33	2,45	2,77	2,58
REQM 2016	3,10	2,50	2,58	2,76	3,37	2,91
Variação 2016/2014 (%)	-19,35	-10,40	-9,69	-11,23	-17,80	-11,34

Fonte: Elaboração Própria a partir dos resultados obtidos.

Em suma, comparando esses modelos em ambientes de menor volatilidade, observam-se desempenhos de previsão bem próximos, com destaque para o modelo ARMA(6,6) que apresentou eficiência preditiva 5,7% e 4,01%, respectivamente, superior aos modelos AR(5) e VAR(2). Entretanto, em uma situação de maior volatilidade, o melhor modelo VAR, VAR(2), por conter maior volume de informações, apresenta desempenho preditivo superior entre todos os modelos aqui empregados.

Vale destacar que autores como Cicarelli e Rebucci (2003), Kapetanios, Labhard e Price (2008), Koop e Korobilis (2013) e Arruda, Tatiwa e Castelar (2011) também apontam para a boa qualidade das previsões geradas por modelos VAR nos prognósticos de diferentes variáveis econômicas como PIB, produção industrial, inflação, taxa de juros, entre outras, em diferentes países.

4.4. Análise Comparativa dos Resultados

Após a comparação analítica dos resultados, procedeu-se uma análise estatística a partir da métrica proposta por Diebold e Mariano (1995) para inferir se, de fato, um modelo é mais eficiente em termos preditivos. Vale destacar que a hipótese nula do teste indica que os modelos possuem desempenhos de previsão semelhantes. Os resultados dos testes comparativos entre os melhores modelos encontram-se dispostos na tabela 5 e foram separados por período de análise. A análise gráfica das previsões dos melhores modelos está disposta em apêndice nos gráficos 6 a 11.

Os resultados do teste de Diebold e Mariano (1995) indicam que não há diferença estatisticamente significativa entre os melhores modelos utilizados para previsão em 2014; ou seja, do ponto de vista estatístico, AR(5), ARMA(6,6) e VAR(2) apresentam desempenho de previsão semelhante. Por outro lado, considerando um período de maior instabilidade, o teste aponta que o modelo VAR(2), de fato, apresenta melhores previsões em relação aos demais.

Tabela 5: Resultado do Teste de Diebold e Mariano (1995)

Previsão para 2014				
Previsões	AR(5)	ARMA(6,6)	VAR(2)	ARMA(6,6)
S(1)	0,51		0,437	
p-valor	0,60		0,66	
Previsão para 2016				
Previsões	AR(6)	VAR(2)	ARMA(6,6)	VAR(2)
S(1)	3,25		2,52	
p-valor	0,00		0,01	

Fonte: Elaboração Própria a partir dos resultados obtidos

Portanto, como os modelos VAR aqui empregados contém variáveis que incorporam as condições de oferta (inflação), de política monetária (M1) e de política fiscal (resultado primário), esse maior volume de informações parece favorecer o seu desempenho preditivo frente aos modelos univariados tradicionais de séries temporais (KAPETANIOS, LABHARD e PRICE, 2008; KOOP e KOROBILIS, 2013).

À guisa de uma referência analítica mais palpável, procedeu-se uma avaliação comparativa dos modelos utilizados nesse trabalho frente ao IBC-Br, considerado “prévia do PIB”. Todavia, é importante ressaltar as vantagens informacionais desse índice frente aos

modelos econométricos, dado a sua atualização periódica/permanente, enquanto que os parâmetros dos modelos econométricos são estimados para um período fixo e, a partir daí, são realizadas previsões. A tabela 6 detalha esse comparativo.

Tabela 6: Comparativos Melhores Modelos com o IBC-Br

Previsão para 2014				
Modelo	AR(5)	ARMA(6)	VAR (2)	IBC-Br
REQM	2,28	2,15	2,24	1,58
Variação IBC-Br/Modelo (%)	-30,70	-26,51	-29,46	-
Previsão para 2016				
Modelo	AR(6)	ARMA(6)	VAR (2)	IBC-Br
REQM	3,11	2,65	2,50	2,07
Variação IBC-Br/Modelo (%)	-33,44	-21,88	-17,2	-

Fonte: Elaboração Própria a partir dos resultados obtidos.

Inicialmente, como em todas as análises anteriores, observa-se que o IBC-Br também apresentou previsões com menor REQM para o período de menor volatilidade. Como esperado, dadas as suas vantagens metodológicas e informacionais, esse indicador apresentou previsões melhores do que as dos modelos econométricos aqui utilizados, todavia, no período de maior volatilidade, suas previsões foram apenas 17,2% melhores do que as do modelo AR(2).

5. CONSIDERAÇÕES FINAIS

O presente estudo selecionou mecanismos de previsão para a atividade econômica do Brasil a partir de modelos AR, ARMA, VAR em ambientes distintos de volatilidade. Para tal, foram consideradas previsões para o ano de 2014 (menor volatilidade), com modelos estimados entre janeiro de 2002 e dezembro de 2013, e para 2016, com estimações entre janeiro de 2002 e dezembro de 2015 (ambiente de maior volatilidade).

Nos moldes de Patterson (2001), os melhores modelos foram selecionados pela sua habilidade preditiva, via Raiz do Erro Quadrático Médio de previsão (REQM). Além disso, fez-se uso da métrica estatística de Diebold e Mariano (1995) para inferir se, de fato, os modelos selecionados são melhores.

Em termos gerais, os resultados apontam que o ambiente de volatilidade é importante para explicar tanto a capacidade preditiva dos modelos econométricos como dos gestores da política econômica, uma vez que as REQM se mostraram superiores para previsões em cenários de maior instabilidade.

Vale destacar que, em termos comparativos, não foi observada diferença estatisticamente significativa entre as habilidades preditivas dos melhores modelos no ambiente de menor volatilidade pelo teste de Diebold e Mariano (1995).

No cenário de maior volatilidade, o modelo VAR (2) se destacou tanto apresentar o menor REQM entre todos os modelos, como pelo fato do teste de Diebold e Mariano (1995) apontar que suas previsões se mostram estatisticamente melhores; ou seja, o fato dos modelos VAR aqui empregados conterem informações das condições de oferta, via inflação, da política monetária, via M1, e da política fiscal, via resultado primário, parece contribuir para o seu melhor desempenho preditivo.

Além disso, há que se ressaltar que diversos autores como Cicarelli e Rebucci (2003), Kapetanios, Labhard e Price (2008), Koop e Korobilis (2013) e Arruda, Tatiwa e Castelar (2011) também ressaltam a boa qualidade das previsões geradas por modelos VAR.

Portanto, a hipótese testada por essa pesquisa foi confirmada; ou seja, na linha de Stock e Watson (2007), há uma maior dificuldade na previsão de variáveis econômicas em um contexto de maior volatilidade.

Assim, se faz necessário que os gestores públicos tenham a dimensão do quanto a

instabilidade econômica e/ou política afeta de maneira danosa a capacidade preditiva destes. E, ainda, previsões de baixa qualidade sobre a atividade econômica podem interferir em projeções de receitas, gerando frustrações no orçamento que provoca redução nos investimentos públicos e, por aumentar a incerteza, desestimula também o setor privado.

Esse trabalho pode ser ampliado por várias frentes. Os principais caminhos para a sua extensão são a aplicação modelos não lineares e o uso técnicas que levem em consideração os efeitos da sazonalidade na qualidade das previsões.

REFERÊNCIAS BIBLIOGRÁFICAS

ADOLFSON, M.; ANDERSSON, M. K.; LINDÉ, J.; VILLANI, M.; VREDIN, A. **Modern Forecasting Models in Action: Improving Macroeconomic Analyses at Central Banks.** Sveriges Riksbank Working Paper Series, nº 188, 2005.

AIZENMAN, J.; MARION, N. Policy Uncertainty, Persistence and Growth. **Review of International Economics**, v. 1, nº 2, p. 145-163, 1993.

ALTIG, D.; CARLSTROM, C. T.; LANSING, K. J. **Computable General-Equilibrium Models and Monetary Policy Advice.** Federal Reserve Bank of Cleveland Working Paper Series, nº 9503, 1995.

ARRUDA, E. F.; TATIWA, R. F e CASTELAR, I. Modelos Lineares e não Lineares da Curva de Phillips para a Previsão da Taxa de inflação no Brasil. **Revista Brasileira de Economia**, v. 65, n. 3, p. 237-252, 2011.

BANCO CENTRAL DO BRASIL. **Sistema Expectativas de Mercado**, 2015. Disponível em: <<http://www.bcb.gov.br/>>. Acesso em: 20 outubro de 2017.

BANCO CENTRAL DO BRASIL. **Modelos de Vetores Auto-Regressivos**, 2008. Disponível em: <<http://www.bcb.gov.br/htms/relinf/port/2008/03/ri200803b7p.pdf>>. Acesso em: 13 novembro de 2017.

BOX, G.; JENKINS, G. **Time Series Analysis: Forecasting and Control.** Holden-Day, San Francisco, 1970.

BRESSAN, A. A.; LIMA, J. E. Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F. **Nova Economia**, Belo Horizonte, v.12, n.1, p.117-140, jan./jun. 2002.

CAIADO, J. **Cointegração e causalidade entre as taxas de juros e a inflação em Portugal.** Gestin, 1, Ano 1, nº 1, p 107-118. 2002.

CAVALCANTI, M. A. F. H. **Modelagem macroeconômica para o Brasil.** In: DUARTE, A. M. Jr.; VARGA, G. Gestão de Risco no Brasil. Rio de Janeiro: Financial consultoria, 2003, p. 279-291.

- CICARELLI, M. E REBUCCI, A. **Bayesian VARs: A survey of the recent literature with an application to the European Monetary System**, IMF Working Paper, No. WP/03/102, 2003.
- DIEBOLD, F. X, MARIANO, R. Comparing predictive accuracy. **Journal of Business and Economic Statistics**, v.13, p. 253-265, 1995.
- FEDERER, J. P. Oil Price Volatility and the Macroeconomy, **Journal of Macroeconomics**, v. 18, n° 1, p.1-26, 1996.
- HAMILTON, J. D. **Time Series Analysis**. Princeton University Press, 1994.
- KAPETANIOS, G., LABHARD, V., PRICE, S. Forecast combination and the Bank of England's suite of statistical forecasting models. **Economic Modelling**, v. 25, n° 4, p. 772-792, 2008.
- KOOP, G.; KOROBILIS, D. Large time-varying parameter VARs. **Journal of Econometrics**, v. 177, n° 2, p. 185-198, 2013.
- MARTIN, P., ROGERS, C.A. Stabilization policy, learning by doing, and economic growth. **Oxford Economic Papers**. v. 49, n° 2, p. 152-166, 1997.
- PATTERSON, K. **An Introduction to Applied Econometrics**. New York Macmillan Press, 2001.
- RAMEY, G.; RAMEY, V. A. Cross-Country Evidence on the Link Between Volatility and Growth. **American Economic Review**, v. 85, n° 5, p. 1138-1151, 1995.
- SIMS, C. Macroeconomics and Reality. **Econometrica**, v. 48, n° 1, p. 1-48, 1980.
- _____. The role of models and probabilities in the monetary policy process. **Brooking Papers on Economic Activity**, v. 2, p. 1-62, 2002.
- STOCK, J.H., e WATSON, M.W. Evidence on Structural Instability in Macroeconomic Time Series Relations. **Journal of Business and Economic Statistics**, v.14, p. 11-29, 1996.
- _____ **Forecasting Inflation**. NBER Working Paper Series. 7023, 1999.
- _____ Why Has U.S. Inflation Become Harder to Forecast?

Journal of Money, Credit and Banking, v.39, n.1, p. 3-33, 2007.

TATIWA, R. F, BIERENS, H.; CASTELAR, I. Forecasting Quarterly Brazilian GDP Growth Rate with Linear and Nonlinear Diffusion Index Models. **Economia Selecta**, v.6, n.3, p 261-292, Dec 2005.


TATIWA, R. F, OLIVEIRA JUNIOR, J. N.; CASTELAR, I. Modelos de índice de difusão para prever a taxa de crescimento do PIB agrícola brasileiro. **Nova economia**, vol.22, n.1, pp.117-139, 2012.

WEST, K. D. **Forecast evaluation**. In Elliot, G., Granger, C. W. J., Timmermann, A., editors, *Handbook of Economic Forecasting*, pages 99–134. Elsevier. 2006.

ZARNOWITZ, V.; MOORE, G. H. **Major changes in cyclical behavior**. in Robert Gordon (ed.), *The American Business Cycle and Change*, The University of Chicago Press, 1986. Chicago and London, 519-582. Disponível em: < <http://www.nber.org/chapters/c10031.pdf> >. Acesso em: 12 de novembro de 2017.


Apêndice

Gráfico 2: Evolução do Indicador de Atividade Econômica




Fonte: Elaboração Própria

Gráfico 3: Evolução do Indicador de Política Monetária




Fonte: Elaboração Própria

Gráfico 4: Evolução do Indicador de Política Fiscal




Fonte: Elaboração Própria

Gráfico 5: Evolução da Inflação IPCA



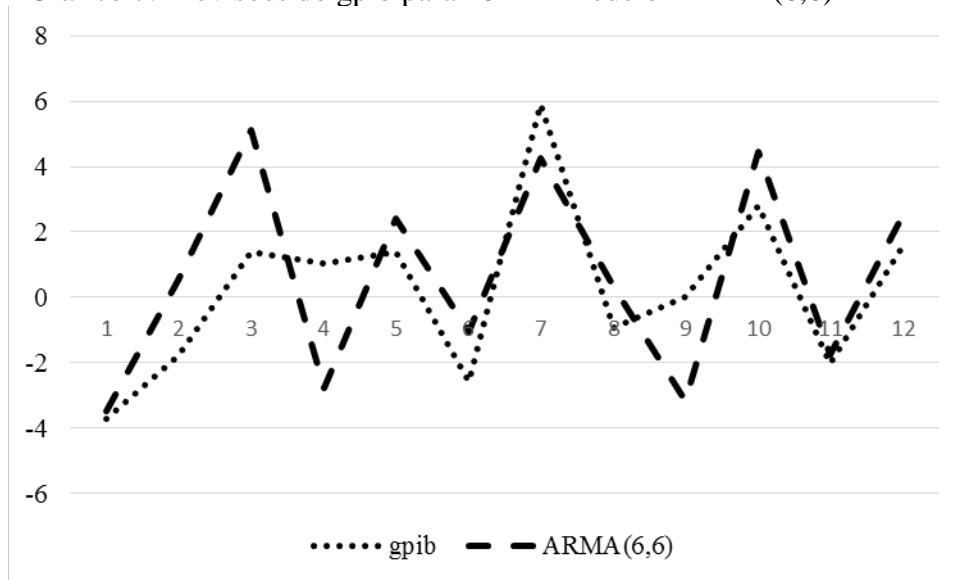
Fonte: Elaboração Própria

Gráfico 6: Previsões do gpib para 2014 – Modelo AR (5)



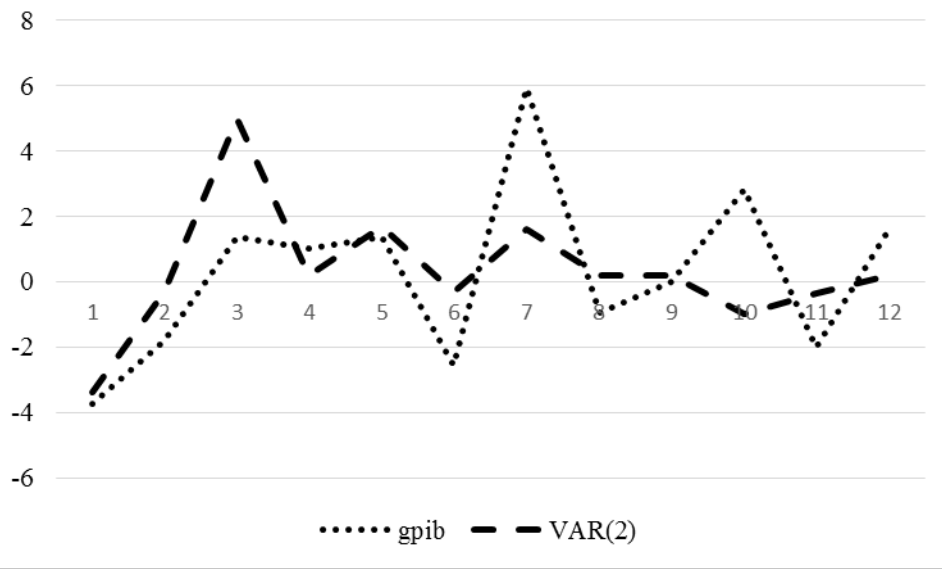
Fonte: Elaboração Própria

Gráfico 7: Previsões do gpib para 2014 – Modelo ARMA (6,6)




Fonte: Elaboração Própria

Gráfico 8: Previsões do gpiB para 2014 – Modelo VAR(2)



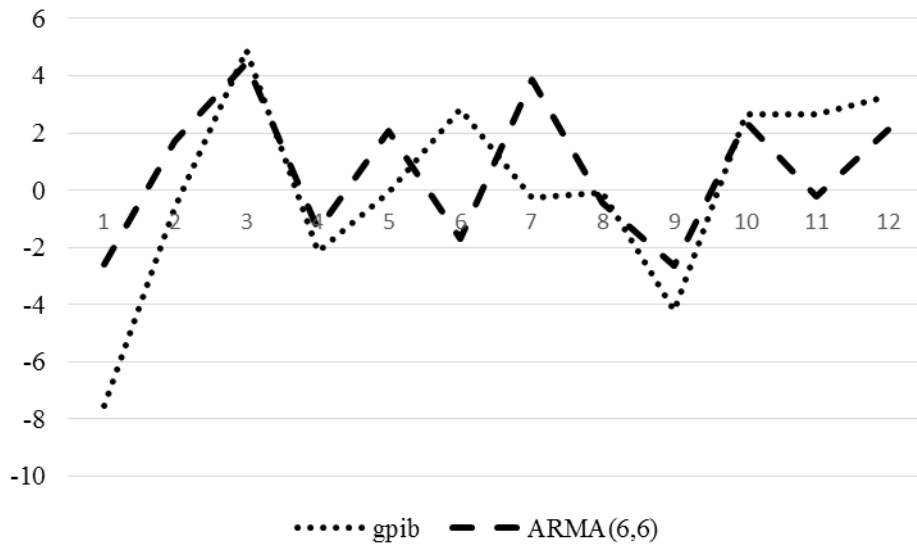
Fonte: Elaboração Própria

Gráfico 9: Previsões do gpiB para 2016 – Modelo AR(6)



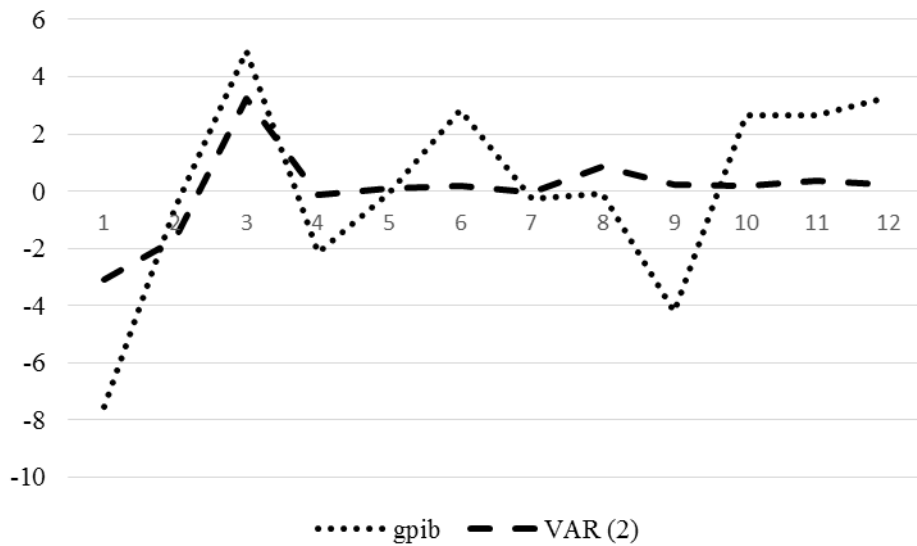
Fonte: Elaboração Própria

Gráfico 10: Previsões do gpiib para 2016 – Modelo ARMA(6,6)



Fonte: Elaboração Própria

Gráfico 11: Previsões do gpiib para 2016 – Modelo VAR (2)



Fonte: Elaboração Própria