



UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, ATUÁRIA E
CONTABILIDADE - FEAAC
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA – CAEN

LÚCIA ANDREA SINDEAUX DE OLIVEIRA

ENSAIOS SOBRE PREÇOS AGROPECUÁRIOS, DINÂMICA
MACROECONÔMICA E NÚCLEO DE INFLAÇÃO NO BRASIL

FORTALEZA

2022

LÚCIA ANDREA SINDEAUX DE OLIVEIRA

ENSAIOS SOBRE PREÇOS AGROPECUÁRIOS, DINÂMICA MACROECONÔMICA E
NÚCLEO DE INFLAÇÃO NO BRASIL

Tese submetida à coordenação do Curso de Pós-Graduação em Economia – CAEN, da Universidade Federal do Ceará – UFC, como requisito parcial para a obtenção do grau de Doutor em Economia. Área de concentração: Economia.

Orientador: Prof. Dr. Luiz Ivan de Melo Castelar

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

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

O48e Oliveira, Lúcia Andrea Sideaux de.
ENSAIOS SOBRE PREÇOS AGROPECUÁRIOS, DINÂMICA MACROECONÔMICA E NÚCLEO DE
INFLAÇÃO NO BRASIL / Lúcia Andrea Sideaux de Oliveira. – 2022.
102 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Faculdade de Economia, Administração, Atuária e
Contabilidade, Programa de Pós-Graduação em Economia, Fortaleza, 2022.

Orientação: Prof. Dr. Luiz Ivan de Melo Castelar.

Coorientação: Prof. Dr. Nicolino Trompieri Neto.

1. preços agropecuários. 2. IPCA. 3. Wavelets. 4. Favar. 5. componentes não observados. I. Título.

CDD 330

LÚCIA ANDREA SINDEAUX DE OLIVEIRA

ENSAIOS SOBRE PREÇOS AGROPECUÁRIOS, DINÂMICA MACROECONÔMICA E
NÚCLEO DE INFLAÇÃO NO BRASIL

Tese submetida à coordenação do Curso de Pós-Graduação em Economia – CAEN, da Universidade Federal do Ceará – UFC, como requisito parcial para a obtenção do grau de Doutor em Economia. Área de concentração: Economia.

Aprovada em: 30/08/2022

BANCA EXAMINADORA

Prof. Dr. Luiz Ivan de Melo Castelar (Orientador)
Universidade Federal do Ceará – UFC

Prof. Dr. Nicolino Trompieri Neto (Coorientador)
Instituto de Pesquisa e Estratégia Econômica do Ceará – IPECE

Prof. Dr. Cristiano da Costa Silva
Universidade Federal do Ceará – UFC

Prof. Dr. Pablo Urano de Carvalho Castelar
Faculdade de Economia, Administração, Atuária e Contabilidade – FEAAC

Prof. Dr. João Paulo Martins Guedes
Universidade Federal do Rio Grande do Norte – UFRN

AGRADECIMENTOS

Agradeço a Deus pela minha existência e pelas vitórias durante essa jornada.

À minha família pelo apoio, especialmente ao John, pelo seu amor e apoio em todas as horas.

Ao meu mentor, Maharish Maresh Yogi, pelas orientações de uma vida mais serena e feliz. À economista Esther Duflo, prêmio Nobel pelo trabalho desenvolvido no alívio global da pobreza, por ter sido também motivação na minha vida acadêmica.

Meus sinceros agradecimentos a todos os professores que tive durante toda a minha vida, especialmente aos do Programa de Pós-Graduação em Economia (CAEN/UFC).

À amizade construída no CAEN durante o doutorado com os funcionários e colegas de sala de aula. Ao professor Dr. Luiz Ivan de Melo Castelar pela orientação. Ao professor Dr. Nicolino Trompieri Neto pela orientação e contribuição da graduação ao doutorado e pela colaboração no terceiro ensaio da tese.

Ao professor Dr. Cristiano Costa da Silva por suas valiosas contribuições em dois ensaios da tese.

Aos membros da banca examinadora, Dr. Pablo Urano de Carvalho Castelar e Dr. João Paulo Martins Guedes, obrigada pela presença e contribuições.

À CAPES, pelo apoio financeiro concedido durante esse período de doutorado.

“Assim como nossa mente pode agir no nosso corpo, podendo até provocar doenças graves, a inflação pode agir na sociedade, podendo até provocar graves problemas”. (Lúcia Sindeaux)

RESUMO

Na trajetória da economia brasileira, destaca-se o setor agropecuário como principal impulsionador no desenvolvimento econômico e social do país, pela capacidade de geração de emprego e renda. Adicionalmente, uma característica do setor agropecuário é a sua natureza cíclica e de circunstâncias peculiares de produção, refletindo diretamente na elevada volatilidade nos preços agropecuários. Este conhecimento volátil dá uma ideia do comportamento dos preços agropecuários, e de sua capacidade de incidir sobre o índice de preços geral, o qual interfere, na condução do regime de metas inflacionárias. Diante desse contexto, foram elaborados três ensaios. O primeiro analisa as assimetrias dos ciclos dos preços agropecuários, preços de mercado e política monetária utilizando-se a análise em tempo-frequência intitulada *Transformada Wavelet*, seguindo Yogo (2008), a qual permitiu-se construir os ciclos das séries analisando a duração, volatilidade e sincronização. Em seguida, aplicou-se o método de Harding-Pagan (2002) para a identificação dos ciclos econômicos. Por fim, para avaliar o grau de persistência destes ciclos, utilizou-se um modelo VAR que identificou o comportamento referente aos choques das variáveis. Os principais resultados mostram que, para o IPA-OG-DI, há uma forte volatilidade tanto nos ciclos de crescimento quanto de recessão, quando comparado com o IGP-M, enquanto na análise da relação causal das variações dos ciclos de M2 e IGP-M, verificou-se que a M2 afeta diretamente o IGP-M, apresentando uma estrutura de realimentação entre a expansão de M2 e o IGP-M. O segundo ensaio analisa as ligações entre os preços agropecuários e variáveis macroeconômicas brasileiras, utilizando um modelo Vetor Autorregressivo Aumentado por Fator (Favar), proposto por Bernanke *et al.*, (2005). Os resultados indicam a existência de fatores comuns entre as séries temporais de um conjunto de bens agropecuários, onde as flutuações comuns são especialmente direcionadas pelas *commodities* de lavouras temporárias e pelos produtos da pecuária. Conjectura-se que o crescimento das exportações chinesas pela cultura de grãos e carne bovina explica em boa medida tal regularidade empírica. A análise de impulso-resposta evidenciou que choques nos fatores comuns dos bens agropecuários afetam o câmbio efetivo, resultando também em pressões inflacionárias. No terceiro ensaio é desenvolvido uma medida de núcleo de inflação para o IPCA com características *foward-looking*, isto é, uma medida de núcleo do IPCA com adequada capacidade preditiva para o nível da inflação futura. Para tanto, utiliza-se o modelo multivariado de componentes não observados, seguindo Harvey (1990) e Koopman *et al.*, (2000). Utilizando as variáveis PIB, IPCA, Selic e M1, seguindo os trabalhos de Bagliano *et al.*, (2002) e Goldfeld (1990). Após a construção do núcleo de inflação para o

IPCA, testam-se as condições para uma medida de núcleo segundo Marques *et al.*, (2003), juntamente com três outras medidas de núcleo fornecidas pelo Banco Central do Brasil. Por último testam-se a acurácia de previsões fora da amostra para o IPCA, utilizando as medidas de núcleo. Os resultados confirmam que a medida de núcleo construído pela modelagem de componentes não observados segue as condições de Marques *et al.*, (2003) e possui um adequado poder preditivo.

Palavras-chave: preços agropecuários; IPCA; Wavelets; Favar; componentes não observados.

ABSTRACT

In the trajectory of the Brazilian economy, the agricultural sector stands out as the main driver of the country's economic and social development, due to its ability to generate employment and income. Additionally, a characteristic of the agricultural sector is its cyclical nature and peculiar production circumstances, directly reflecting on the high volatility in agricultural prices. This volatile knowledge gives an idea of the behavior of agricultural prices, and their ability to affect the general price index, which interferes in the conduct of the inflation targeting regime. Given this context, three essays were elaborated. The first analyzes the asymmetries of cycles of agricultural prices, market prices and monetary policy using the time-frequency analysis entitled Wavelet Transform, following Yogo (2008), which allowed the construction of series cycles by analyzing duration, volatility and synchronization. Then, the Harding-Pagan (2002) method was applied to identify economic cycles. Finally, to assess the degree of persistence of these cycles, a VAR model was used, which identified the behavior related to the shocks of the variables. The main results show that, for the IPA-OG-DI, there is a strong volatility both in the growth and recession cycles, when compared with the IGP-M, while in the analysis of the causal relationship of the variations of the M2 and IGP-M, it was verified that the M2 directly affects the IGP-M, presenting a feedback structure between the expansion of M2 and the IGP-M. The second essay analyzes the links between agricultural prices and Brazilian macroeconomic variables, using a Factor Augmented Vector Autoregressive (Favar) model, proposed by Bernanke *et al.*, (2005). The results indicate the existence of common factors between the time series of a set of agricultural goods, where the common fluctuations are especially driven by temporary crop commodities and by livestock products. It is conjectured that the growth of Chinese exports for the cultivation of grains and beef largely explains this empirical regularity. The impulse-response analysis showed that shocks to the common factors of agricultural goods affect the effective exchange rate, also resulting in inflationary pressures. In the third essay, a core measure of inflation for the IPCA with forward-looking characteristics is developed, that is, a core measure of the IPCA with adequate predictive capacity for the level of future inflation. For this purpose, the multivariate model of unobserved components is used, following Harvey (1990) and Koopman *et al.*, (2000). Using the GDP, IPCA, SELIC and M1 variables, following the work of Bagliano *et al.*, (2002) and Goldfeld (1990). After constructing the core inflation for the IPCA, the conditions for a core measure according to Marques *et al.*, (2003), along with three other core measures provided by the Central Bank of Brazil. Finally, the accuracy of out-of-sample forecasts for the IPCA is

tested, using core measures. The results confirm that the core measure constructed by modeling unobserved components follows the conditions of Marques *et al.*, (2003) and has adequate predictive power.

Keywords: agricultural prices; IPCA; Wavelets; Favar; components not observed.

LISTA DE GRÁFICOS

Gráfico 1 –	Fases cíclicas de expansão e retração de preços agropecuários.....	21
Gráfico 2 –	Evolução temporal das séries em análise, 2001.07 – 2018.06.....	35
Gráfico 3 –	Evolução temporal dos ciclos extraídos 2001.07 – 2018.06.....	36
Gráfico 4 –	Ciclos datados dos índices econômicos, 2001.07 – 2018.06.....	37
Gráfico 5 –	Funções resposta ao impulso do Modelo VAR com as 3 variáveis (em pares.....	41
Gráfico 6 –	Função de impulso resposta da taxa de câmbio – Brasil.....	57
Gráfico 7 –	Função de impulso resposta do IPCA-Brasil.....	58
Gráfico 8 –	Função de impulso resposta da taxa de juros – Brasil.....	59
Gráfico 9 –	Funções de impulso resposta do petróleo Brent-Brasil.....	60
Gráfico 10 –	Função de impulso resposta do IBC-Brasil.....	61
Gráfico 11 –	Função de impulso resposta do índice de incerteza econômica-Brasil.....	62
Gráfico 12 –	IPCA observado e Núcleos para o IPCA - 2002.1 a 2021.6.....	78
Gráfico 13 –	IPCA observado e previsões fora da amostra dos núcleos.....	83

LISTA DE QUADROS

Quadro 1 – Estudos mais citados nos últimos dezesseis anos (2002-2018).....	24
---	----

LISTA DE TABELAS

Tabela 1 –	Estatísticas descritivas das séries em análise.....	32
Tabela 2 –	Estatísticas descritivas dos ciclos em análise.....	33
Tabela 3 –	Médias dos ciclos, 2001.07 – 2018.06.....	38
Tabela 4 –	Teste de causalidade de Granger.....	39
Tabela 5 –	Decomposição da variância do IGP-M.....	41
Tabela 6 –	Decomposição da variância do IPA-OG-DI.....	43
Tabela 7 –	Decomposição da variância do M2.....	43
Tabela 8 –	Estatísticas descritivas para o IPCA e núcleos do IPCA.....	79
Tabela 9 –	Testes de raiz unitária Dickey-Fuller Aumentado (ADF) e KPSS.....	79
Tabela 10 –	Testes de cointegração bivariado.....	80
Tabela 11 –	Teste de causalidade de Granger aplicado ao VEC.....	81
Tabela 12 –	Teste da razão de verossimilhança (LR) para restrições nos parâmetros de cointegração.....	81
Tabela 13 –	Avaliação das previsões fora da amostra para o IPCA.....	83
Tabela 14 –	Teste de comparação de acurácia preditiva Diebold–Mariano para o núcleo IPCA_CN no período 2021.07-2022.06.....	85

SUMÁRIO

1	INTRODUÇÃO GERAL.....	15
2	ANÁLISE DAS ASSIMETRIAS DOS CICLOS: PREÇOS AGROPECUÁRIO, PREÇO DE MERCADO E POLÍTICA MONETÁRIA DA ECONOMIA BRASILEIRA.....	19
2.1	Introdução.....	19
2.2	Revisão da literatura.....	20
2.2.1	<i>Ciclos e ligações dos preços de agropecuários globais.....</i>	<i>21</i>
2.3	Metodologia.....	25
2.3.1	<i>Descrição da base de dados.....</i>	<i>26</i>
2.3.2	<i>Transformada de Wavelets (TW)</i>	<i>26</i>
2.3.3	<i>Análise de Wavelet Multirresolução (MR)</i>	<i>27</i>
2.3.4	<i>Filtro Wavelet Biortogonal.....</i>	<i>28</i>
2.3.5	<i>Identificação dos ciclos segundo Harding e Pagan (2002)</i>	<i>29</i>
2.3.6	<i>Teste de causalidade de Granger em um VAR bivariado.....</i>	<i>30</i>
2.4	Resultados.....	32
2.5	Conclusão.....	43
3	ANÁLISE DAS LIGAÇÕES DOS PREÇOS AGROPECUÁRIOS E VARIÁVEIS MACROECONÔMICAS BRASILEIRAS: UMA APLICAÇÃO DO MODELO – FAVAR.....	46
3.1	Introdução.....	48
3.2	Revisão da literatura.....	48
3.3	Metodologia.....	51
3.3.1	<i>Modelo autorregressivo vetorial aumentado por Fator (Favar)</i>	<i>52</i>
3.4	Resultados.....	54
3.4.1	<i>Funções de impulso resposta (FIR)</i>	<i>55</i>
3.5	Conclusão.....	62
4	NÚCLEO DA INFLAÇÃO: UMA APLICAÇÃO DO MODELO DE COMPONENTES NÃO OBSERVADOS PARA O BRASIL.....	65
4.1	Introdução.....	65
4.2	Revisão da literatura.....	66
4.2.1	<i>Modelagens de núcleos.....</i>	<i>68</i>
4.3	Metodologia.....	70

4.3.1	<i>Modelo de componentes não observados</i>	70
4.3.2	<i>Modelo linear univariado</i>	70
4.3.3	<i>Modelos lineares multivariados</i>	72
4.3.4	<i>O filtro de Kalman</i>	73
4.3.5	<i>Condições para uma medida de núcleo de inflação</i>	74
4.3.6	<i>O Teste Diebold-Mariano para acurácia de previsão fora da amostra</i>	76
4.4	Análise dos dados e resultados do modelo	77
4.4.1	<i>Testes de raiz unitária</i>	79
4.4.2	<i>Análise das Condições para o núcleo segundo Marques et al., (2003)</i>	80
4.4.3	<i>Resultados das previsões e Acurácia fora da amostra dos núcleos</i>	82
4.5	Conclusão	86
	REFERÊNCIAS	88
	APÊNDICE	97

1 INTRODUÇÃO GERAL

O processo de crescimento acelerado das economias ditas emergentes, especialmente a chinesa, possibilitou o aumento da demanda por *commodities* agrícolas, beneficiando a balança comercial brasileira visto que a China é um dos principais parceiros comerciais do Brasil. Este foi um dos motivos para o aumento dos preços desses produtos.

Uma característica conspícua do setor agropecuário brasileiro é ser o propulsor da balança comercial, uma vez que pauta a agenda nacional de exportações. No período de *boom*, entre 2003 a 2008, a escalada do índice de preços de *commodities* agrícolas e minerais (sem petróleo) praticamente dobrou, apresentando uma retração, por pouco período de tempo, devido ao efeito da crise econômica de 2008, retornando a escalada de preço em 2009 (MARGARIDO *et al.*, 2010).

O Brasil e os demais países da América Latina, tiveram um crescimento econômico associado à alta valorização dos preços internacionais desses produtos e o consequente avanço do intercâmbio entre eles. Importa destacar que no período de *boom* das *commodities* (2003-2011), o Brasil registrou uma taxa média anual de crescimento econômico de 3,88%, muito relevante quando comparamos com o período do pós-*boom* (2012-2013) conforme visto por Black (2015).

Posto isso, alguns autores apontam que os preços das *commodities* são indicadores úteis para prever a inflação (AWOKUSE, 2005; CHEUNG, 2009; HASSAM; SALIM, 2011; GOSPODINOV; NG, 2013; SOUZA, 2016).

Do ponto de vista de Anzuini *et al.*, (2013), os preços das *commodities* agrícolas podem ser influenciados pela taxa de juros de curto prazo através de tomada de decisões dos investidores, uma vez que taxas de juros baixa incentivam um aumento na demanda dos investidores por ativos financeiros alternativos. Como as *commodities* são mercadorias negociadas no mercado financeiro, o aumento da demanda por esses ativos aumenta os preços desses produtos.

Com base nesse cenário, o primeiro ensaio avança em relação à literatura nacional por aplicar um método diferenciado para analisar as assimetrias dos ciclos dos preços agropecuários, preços de mercado e política monetária da economia brasileira. Primeiramente, fez-se uma análise histórica da caracterização das fases dos preços, partindo da hipótese segundo a qual uma política monetária expansionista ou restritiva deveria ser testada também pelo conjunto dos preços agropecuários.

Para atender os objetivos, utilizou-se a transformada de *Wavelet*, segundo Yogo (2008), a qual permite construir os ciclos econômicos das séries de acordo com a concepção clássica de Burns e Mitchell (1946). Com base na decomposição de *Wavelet*, foram investigados a duração, volatilidade e sincronização dos ciclos econômicos brasileiros. Em seguida, aplica-se o método de Harding-Pagan (2002) para identificar os ciclos dos índices econômicos e determinar a trajetória de expansão e de recessão dos índices macroeconômicos. Por fim, para avaliar o grau de persistência destes ciclos, utiliza-se um modelo VAR bivariado que identifica o comportamento referente aos choques dos preços agropecuários, preços de mercado e política monetária sobre ciclos econômicos.

No segundo ensaio são analisadas as ligações entre os preços agropecuários e as variáveis macroeconômicas brasileiras, por meio de um modelo Vetor Autorregressivo Aumentado por Fator (Favar), proposto por Bernanke *et al.*, (2005), e tendo como base o estudo de Lombardi *et al.*, (2012). Por meio desse modelo, as variáveis observadas são inseridas no modelo VAR, além do conjunto de estrutura dinâmica de fatores latentes. Na prática, a partir de um conjunto de séries desagregadas, são estimados, via componentes principais, os fatores latentes em relação ao conjunto de preços de *commodities*, para em seguida inseri-los em uma especificação VAR, conjuntamente com as variáveis macroeconômicas selecionadas. As evidências encontradas indicam a existência de fatores comuns entre as séries temporais de um conjunto de bens agropecuários, onde as flutuações comuns são especialmente direcionadas pelas *commodities* de lavouras temporárias e pelos produtos da pecuária. Conjectura-se que o crescimento das exportações chinesas pela cultura de grãos e carne bovina explica em boa medida tal regularidade empírica. A análise de impulso-resposta evidenciou que choques nos fatores comuns dos bens agropecuários afetam o câmbio efetivo, resultando também em pressões inflacionárias. Na mesma linha, variações não antecipadas na dinâmica dos fatores afetam as expectativas dos agentes, impulsionando a incerteza no ambiente econômico nacional.

No terceiro ensaio é construída uma medida de núcleo para o índice de inflação IPCA, utilizando como metodologia um modelo multivariado de componentes não observados seguindo Harvey (1990) e Koopman *et al.*, (2000). O modelo é composto pelas variáveis macroeconômicas PIB real, taxa de juros SELIC nominal, oferta do agregado monetário M1 em termos reais e a taxa de inflação IPCA seguindo os trabalhos de Bagliano *et al.*, (2002) e Goldfeld (1990). O núcleo gerado pelo modelo de componentes não observados (IPCA_CN) corresponde a tendência estocástica estimada para o IPCA. Em seguida é verificado se o núcleo

produzido atende as condições para uma medida de núcleo, segundo Marques *et al.*, (2003) e se ele possui adequada capacidade de previsão fora da amostra. Tanto os testes das condições como a análise da capacidade preditiva são realizadas em comparação com três outros núcleos produzidos pelo Banco Central do Brasil, o núcleo por exclusão sem monitorados e alimentos no domicílio (IPCA_EX), o núcleo de dupla ponderação (IPCA_DP) e o núcleo de médias aparadas com suavização (IPCA_MS). As condições de Marques *et al.*, (2003) indicaram que apenas a medida de núcleo gerada pela modelagem de componentes não observados (IPCA_CN) é não enviesada tal que comporta-se como um indicador antecedente para o IPCA. As previsões fora da amostra confirmam que o núcleo IPCA_CN possui um poder preditivo superior às previsões dos núcleos do BCB testados e a previsão do próprio IPCA observado, dado os menores erros de previsão e a confirmação de maior acurácia indicado pelo teste Diebold-Mariano (1995).

2 ANÁLISE DAS ASSIMETRIAS DOS CICLOS: PREÇOS AGROPECUÁRIO, PREÇO DE MERCADO E POLÍTICA MONETÁRIA DA ECONOMIA BRASILEIRA

Na trajetória da economia brasileira, destaca-se o setor agropecuário como principal impulsionador no desenvolvimento econômico e social do país, pela capacidade de geração de emprego e renda. Adicionalmente, este setor é o propulsor da balança comercial, uma vez que pauta a agenda nacional de exportações. Entretanto, uma característica conspícua do setor agropecuário é a sua natureza cíclica e circunstâncias peculiares de produção, comercialização, meios de transportes, refletindo diretamente na elevada volatilidade nos preços agropecuários. Este conhecimento volátil dá uma ideia do comportamento dos preços dos produtos agropecuários, e de sua capacidade de incidir sobre o índice de preços geral, o qual interfere, por sua vez, na condução do regime de metas inflacionárias.

A condução do regime de metas inflacionárias é distinta quando comparado o Brasil a países economicamente desenvolvidos, nomeadamente no que diz respeito ao valor agregado dos produtos exportados. Países exportadores de *commodities*, com maior pauta de exportação em produtos de origem primária, no período do *boom* de *commodities*, tiveram impacto direto nos termos de troca conduzindo a mudanças na taxa de câmbio real associado ao aumento dos preços domésticos (SOUZA, 2016).

Em particular, entre o período 2000-2003 e 2015-2016, os efeitos do superciclo das *commodities* na economia brasileira não foram poucos, estando associados à expansão na demanda global decorrente do processo de urbanização e do crescimento da renda em países emergentes, especificamente a China, que é uma das maiores importadoras das *commodities* agropecuárias brasileiras.

As *commodities* são responsáveis por 65% das exportações anuais do Brasil, segundo a Conferência das Nações Unidas sobre Comércio e Desenvolvimento – UNCTAD (2017). E, pontualmente, no período de 2000-2003 e 2015-2016, os preços subiram de forma constante graças à demanda crescente de economias emergentes como a China e a Índia (WORLD BANK, 2021).

Diante deste contexto, para autores como Cheung (2009); Hassan e Salim (2011); Gospodinov e Ng (2013); Souza, (2016), os preços das *commodities* são como indicadores na predição da inflação. Em linhas gerais, o processo de globalização e a expansão do mercado agropecuário estabeleceram as bases que aproximaram o comércio e o mercado financeiro. Com efeito, os preços agrícolas deixaram de responder apenas aos estímulos de determinação de quantidade e preços dos produtos conforme a lei de oferta e demanda, e agora passaram a refletir

a crescente conversão das *commodities* em ativos criados e negociados no mercado financeiro. A formação dos preços dos produtos primários, sobretudo os agropecuários, pode estar relacionada à financeirização e aos fundamentos como visto por Serigati (2012).

2.1 Introdução

As explicações sobre os fundamentos ou mercados reais podem ser compreendidas pela crescente demanda mundial de *commodities*, tendo a China como a principal consumidora de matérias-primas brasileiras para a produção industrial e o consumo alimentício de sua população; o aumento por esses produtos alterou seus preços ocasionando o efeito-preço das exportações¹ (SOUZA, 2016).

As explicações sobre a financeirização, ou mercados financeiros nos termos de Serigati (2012), podem ser compreendidas pelo lado do câmbio, uma vez que a desvalorização do dólar americano pode ter induzido diretamente os preços de todas as *commodities*, agrícolas ou minerais, por serem negociadas em dólar. Portanto, uma desvalorização desta moeda conduz a um aumento no preço desses produtos para manter seu valor real, também pode ser explicado pela influência das atividades especulativas nos mercados de futuros².

Associada a tantas particularidades, um obstáculo das *commodities* agropecuárias, são as grandes flutuações de preços que ocorrem frequentemente, em curto período de tempo em função de sazonalidade de clima, aspectos de mercado e conjunturais. Com efeito, a análise dos preços das *commodities*, tem sido, objeto de interesse dos agentes acadêmicos como Margarido *et al.*, (2010); Alberola-Ila *et al.*, (2016); Lélis *et al.*, (2016); Bredow *et al.*, (2016). Com base nesse cenário, viu-se a necessidade de explorar a característica cíclica dos preços agropecuários como o intuito de saber quais canais de transmissão interferem nos preços agropecuários e quais as justificativas para tal influência.

Nesse contexto, o objetivo deste estudo é analisar as assimetrias dos ciclos dos preços agropecuários, preços de mercado e política monetária da economia brasileira. Para isto, o estudo parte da hipótese segundo a qual uma política monetária expansionista ou restritiva

¹ Para uma melhor explicação, ver o estudo de Rosnick e Weisbrot (2014); os autores fazem uma abordagem mais abrangente sobre o efeito-preço das exportações de *commodities*.

² Segundo Serigati (2012), a atividade no mercado futuro através do preço das *commodities* (ativos), com o aumento nos preços destes produtos, e como os movimentos nos mercados futuros influenciam a formação do preço no mercado *spot*, cria-se o canal pelo qual as atividades financeiras influenciam os preços agrícolas. Porém, a formação dos preços agrícolas não se determina pelos mercados futuros, mas na combinação do lado real e financeiro da economia. No lado real, determina a tendência a ser seguida pelos preços e, o lado financeiro intensifica esta tendência e incorpora maior volatilidade nos preços.

deveria ser testada também pelo conjunto dos preços agropecuários. Logo, faz-se uma análise histórica da caracterização das fases dos preços, utilizando três procedimentos:

Inicialmente, utilizou-se a transformada de *wavelet* de acordo com (YOGO, 2008). Este modelo fornece uma melhor resolução no domínio do tempo, na medida em que as funções de base da *wavelet* são localizadas no tempo (ou escala), o que é útil para capturar a volatilidade variável do ciclo de negócios. Onde tem sido instrumento de previsão bem-sucedido a começar com o trabalho de Burns e Mitchell (1946).

Em seguida, aplica-se o método de Harding e Pagan (2002), para identificar os ciclos dos índices econômicos e determinar a trajetória de expansão e de recessão dos índices macroeconômicos. Os ciclos têm duração mínima de um ano e a duração máxima não ultrapassa doze anos (BURNS; MITCHELL, 1946). Já para Harding e Pagan (2002), o ciclo tem duração mínima de 15 meses e a amplitude de mudança do estágio dos ciclos (expansão, recessão, contração e recuperação) dura pelo menos seis meses. Por fim, para avaliar o grau de persistência destes ciclos, utiliza-se um modelo VAR bivariado que identifica o comportamento dos choques nos preços agropecuários, preços de mercado e política monetária sobre ciclos econômicos.

Dado que a economia é composta pela interação de variáveis macroeconômicas, tais como os preços, quantidades transacionadas no mercado, as taxas de juros, as taxas de câmbio entre outras, este estudo contribui para o uso de informações desagregadas dos indicadores macroeconômicos, a saber: preços agropecuários e de mercado e política monetária a fim de caracterizar a trajetória temporal dos ciclos econômicos no Brasil.

Para isto, conjectura-se que o entendimento dos canais de transmissão entre os choques nos preços agropecuários e de mercado possuem conteúdo informacional para o desenho da política monetária com vistas à estabilização dos preços gerais da economia e a consequente promoção de um ambiente de crescimento econômico viável.

2.2 Revisão da literatura

Segundo Beveridge e Nelson (1981), as séries macroeconômicas podem ser decompostas em dois componentes que representam os movimentos transitórios (ciclos) e os movimentos permanentes (tendências), estas são características importantes, permitem a compreensão do comportamento dos preços agropecuários.

Os ciclos referem-se aos movimentos recorrentes de elevação e queda em torno do nível médio da tendência, adicionalmente os movimentos para cima e para baixo em torno da

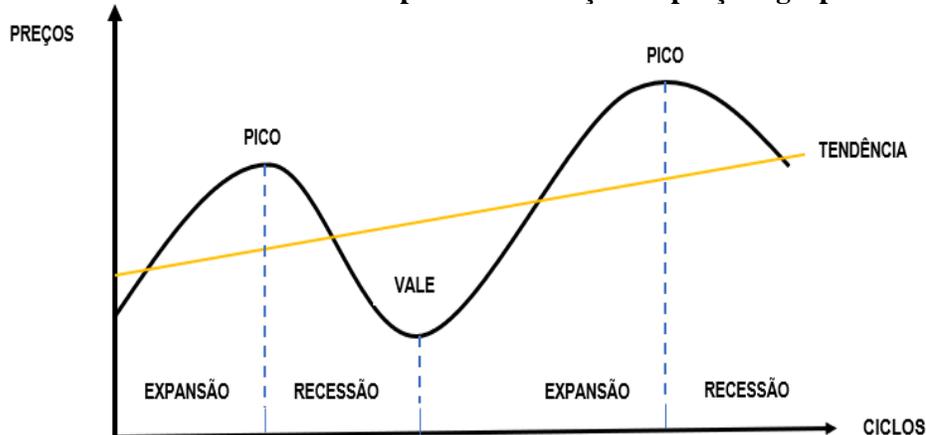
tendência podem ser estritamente periódicos ou aproximadamente periódicos, logo, eles podem variar em comprimento e magnitude.

Ainda assim, ciclo, são caracterizados como uma sequência de mudanças periódicas, mas não repetidas, que apresentam períodos de expansão, recessão, contração e recuperação, que está associada a uma nova expansão no início do ciclo seguinte. A cada mudança nos ciclos, encontramos o ponto de mudança no comportamento do ciclo (inflexão) que significa uma mudança de uma trajetória de expansão para recessão.

De acordo com a concepção clássica de Burns e Mitchell (1946), a duração mínima de um ciclo corresponde a um ano e a duração máxima não ultrapassa doze anos. Na concepção de Harding e Pagan (2002), o ciclo tem duração mínima de 15 meses e a amplitude de mudança do estágio dos ciclos (expansão, recessão, contração e recuperação) dura pelo menos 6 meses.

O gráfico 1 mostra as fases cíclicas de expansão e de retração dos preços agropecuários. Cada ciclo inicia num “vale”, o ponto mais baixo de preços, mostrando o final de um período de retração, em seguida se inicia o ciclo de expansão até o “pico” ponto mais alto do ciclo de expansão seguindo-se posteriormente de outro período de retração.

Gráfico 1 – Fases cíclicas de expansão e retração de preços agropecuários



Fonte: Elaboração própria.

2.2.1 Ciclos e ligações dos preços de agropecuários globais

Nesta seção, estão apresentados os trabalhos mais citados e modelos econométricos mais utilizados em relação à análise do comportamento dos preços agropecuários. Os trabalhos Saghaian *et al.*, (2002); Bakucs *et al.*, (2006) e Asfaha e Jooste (2007), utilizam preços agrícolas (e industriais), taxa de câmbio e política monetária, tomando como referência a teoria de

ultrapassagem (*overshooting*) elaborada por Dornbusch (1976) para as economias: Estados Unidos da América, Eslovênia e da África do Sul respectivamente.

A propósito, Saghalian *et al.*, (2002), além de testar o modelo de Dornbusch (1976), também fizeram uso do chamado Modelo Vetorial de Correção de Erro (VEC). Os autores identificaram, na hipótese de superação dos preços agrícolas, uma mudança monetária com efeitos reais de curto prazo. Isso indica que a oferta monetária não é neutra e os impactos monetários podem mudar os preços relativos no curto prazo. Esse tipo de resultado também pode ser visto em Bakucs *et al.*, (2006), para a economia da Eslovênia. Já Asfaha e Jooste (2007), utilizam a mesma metodologia, sendo para economia da África do Sul. Os resultados mostram que o impacto da oferta monetária nos preços agrícolas é muito significativo. No curto prazo, acontece *overshoot* de preços (agrícolas/industrializados) após choques monetários.

Awokuse (2005), Gilbert (2010) e Anzuini *et al.*, (2013) utilizaram o Vetor Autorregressivo (VAR) com o objetivo de identificar o principal instrumento de política macroeconômica que afeta os preços agrícolas das economias dos Estados Unidos e de países emergentes. De acordo com Awokuse (2005), as mudanças na oferta monetária têm pouca interferência sobre os preços agrícolas. E o principal instrumento de política macroeconômica com influência nos preços agrícolas são as flutuações nas taxas de juros e câmbio.

Por outro lado, Gilbert (2010) identificou um maior choque de demanda no setor agrícola, no período de 2007 a 2008. Alguns preços agrícolas, por exemplo, grãos e oleaginosas, aumentaram em razão do crescimento da China e de outras economias asiáticas, principalmente por medidas de política monetária expansionistas nos anos anteriores.

Anzuini *et al.*, (2013) verificaram que uma política monetária expansionista ajuda a prever flutuações nos preços das *commodities*; os resultados mostram que choques de política monetária anteriores ao período de 2003 a 2008 contribuíram para o aumento do índice de preços geral de *commodities* e seus principais componentes.

Shaoping e Xiaotao (2014) aplicam um método de decomposição dos ciclos codependentes usando três variáveis, a saber: índice de preços ao consumidor (CPI), índice de preços ao produtor agrícola (APP) e política monetária (M2). Os dados são trimestrais de 2001 a 2012. Os autores utilizam uma abordagem de decomposição multivariada de Beveridge-Nelson-Stock-Watson. Os resultados da decomposição apresentam a codependência entre as três variáveis. Os ciclos APP e CPI têm uma codependência pouco significativa com o ciclo M2. O ciclo APP antecipa o ciclo CPI e exhibe uma formação cíclica de aumentos e quedas. A forte codependência entre os ciclos M2 e CPI confirmam a eficácia da contração monetária para

conter a inflação. No entanto, quando a variável APP aumenta acentuadamente ou está na fase crescente de elementos do ciclo, a China deve enfatizar o controle da variável APP e adiar uma política monetária moderada até que o ciclo APP se torne estável. Os autores afirmam que a formação do ciclo para a variável M2 não é clara.

Alguns autores, como Khundrakpam e Das (2011), Amatov e Dorfman (2017) e Hatzenbuehler *et al.*, (2016) utilizaram um VEC tomando como principais variáveis de análise a política monetária, a taxa de juros e os índices de preços agrícolas para as economias Índia e Estados Unidos, respectivamente. Khundrakpam e Das (2011) descobriram que os índices de preços agrícolas indiano, são mais sensíveis a variações na oferta de moeda, em vez da taxa de juros, um claro indicativo de que a oferta monetária não é neutra na determinação dos índices de preços agrícolas.

Já para a economia americana, Amatov *et al.*, (2015) estudam o impacto da política monetária, índice de preços de todas as *commodities* e o índice de preço agrícolas no período (1992-2013), os seus resultados mostram que ambos os índices de preço global de *commodities* e de preço agrícola reagem positivamente a taxas de juros mais baixas, sendo que este último tem um período de ajuste mais longo do que aquele outro, resultado que difere da maioria da literatura. Já em Hatzenbuehler *et al.*, (2016), o modelo VEC de curto prazo mostrou que a capacidade de resposta dos preços agrícolas às mudanças na taxa de câmbio é maior devido a fatores de *overshooting* na economia dos EUA.

Mais recentemente, Bhattacharya (2017)³ examina o efeito da política monetária na estabilização dos preços agrícolas com evidências em economias desenvolvidas e emergentes. Usando um painel de dados para o período 2006-2016, identificou-se uma relação positiva e significativa no aumento do índice de preço agrícola quando ocorre um aperto na política monetária para as duas economias, e um aperto na política monetária poderá acelerar a inflação tanto dos alimentos (índice de preço agrícola) quanto causar um desequilíbrio na economia por um período de tempo.

Tan *et al.*, (2017) e Wagan *et al.*, (2018) examinaram a política monetária como variável fundamental na determinação dos preços agrícolas nas economias: China, Índia, Paquistão e incorporam o modelo VAR aumentado com fatores. Tan *et al.*, (2017) examinam o impacto da política monetária sobre o preço agrícola na China no período 2005-2016. Os resultados mostram que, no curto prazo, a política monetária tem forte interveniência sobre os

³ Seguindo essa mesma abordagem, destacam-se Aoki (2001); Soto (2003); Pourroy *et al.*, (2016) e Catao e chang(2015).

preços agrícolas e no longo prazo (além de 50 meses), tanto a oferta monetária quanto a taxa de juros, não têm impacto sobre os preços agrícolas. A margem de erro de previsões de longo prazo mostra a taxa de juros como a principal indutora de volatilidade nos preços agrícolas.

Wagan *et al.*, (2018) examinam o efeito da política monetária sobre o crescimento agrícola, emprego e preços agrícolas, nos anos de 1995 a 2016 para a Índia e o Paquistão. O estudo revela que uma política monetária contracionista produz um efeito inverso entre as variáveis, reduzindo os preços agrícolas e a produção agrícola, enquanto a taxa de desemprego agrícola aumenta significativamente.

No Quadro 1 estão detalhados os principais autores que realizaram estudos sobre ciclos e tendências dos preços agropecuários. Importante enfatizar que o presente estudo traz uma abordagem diferenciada para analisar os ciclos e tendências dos preços agropecuários.

Quadro 1 - Estudos mais citados nos últimos dezesseis anos (2002-2018)

Autor (es) / Ano	Metodologia	Variáveis	País
Saghaian <i>et al.</i> , 2002;	DORNBUSCH, R - Hipótese (<i>overshooting</i>), e (VEC)	Preços agrícolas e não agrícolas, taxa de câmbio, política monetária (M1).	EUA
Awokuse (2005)	Modelo (VAR)	Política monetária, preços agrícolas, taxa de câmbio, taxa de juros.	EUA
Bakucs <i>et al.</i> , (2006)	DORNBUSCH, R - Hipótese (<i>overshooting</i>), e (VEC)	Preços agrícolas e não agrícolas, taxa de câmbio, política monetária (M1).	Eslovênia
Asfaha e Jooste (2007)	Modelo (VEC)	Preços agrícolas, não agrícolas e política monetária.	África do Sul
Gilbert (2010)	Modelo (VAR)	Política monetária (M2), índice de preços agrícolas, taxa de câmbio.	Economias desenvolvidas e emergentes
Khundrakpam e Das (2011)	Modelo (VEC)	Preços agrícolas e manufaturados à mudança na taxa de juros e na oferta de moeda	Índia

Anzuini <i>et al.</i> (2013)	Modelo (VAR)	Política monetária e os preços das commodities	EUA
Shaoping e Xiaotao (2014)	Decomposição de Ciclo Codependente	Índice de preço agrícola, índice de preço do consumidor e política monetária (M2).	China
Amatov (2015)	Modelo (VEC)	Índice de preço agrícola, índice de preço não agrícola, política monetária, taxa de juros.	EUA
Hatzenbuehler <i>et al.</i> , (2016)	Modelo (VEC)	Preços agrícolas e taxa de câmbio	EUA
Tan (2017)	Modelo (FAVAR)	Política monetária e preço agrícola	China
Bhattacharya (2017)	Painel de dados	Política monetária, índice de preço agrícola e taxa de juros.	Economias desenvolvidas e emergentes
Wagan <i>et al.</i> , (2018)	Modelo (FAVAR)	Política monetária, emprego agrícola e preço agrícola.	Índia e Paquistão.

Fonte: Elaboração própria.

2.3 Metodologia

Para analisar as assimetrias dos ciclos do índice do preço agropecuário, índice de preço geral e política monetária (M2), o estudo adota três procedimentos. Primeiro, para fazer a decomposição dos índices, utilizou-se a análise em tempo-frequência intitulada *Transformada Wavelet*, seguindo Yogo (2008), no qual permitiu a decomposição das séries a partir de mudanças de escala de intervalos.

Segundo, optou-se pelo método de Harding e Pagan (2002), para identificar os ciclos dos índices econômicos e determinar a trajetória de expansão e de recessão dos índices macroeconômicos brasileiros. Por fim, para verificar correlações entre os ciclos comuns e os ciclos individuais, empregamos o teste de causalidade de Granger conforme (BUENO, 2008),

para verificar a capacidade preditiva dos ciclos. O teste de causalidade nos auxilia a mensurar se valores passados e correntes do ciclo de preços agropecuários ajudam a prever os valores futuros de preços agropecuários.

2.3.1 Descrição da base de dados

Para decompor os ciclos, definem-se as seguintes variáveis: Índice de Preços ao Produtor Amplo por Origem (IPA-OG-DI)⁴, o Índice Geral de Preços de Mercado (IGP-M) e política monetária (M2)⁵. As variáveis têm periodicidade mensal, compreendendo 204 observações no período de julho/2001 a junho/2018, sendo obtidas no site do Instituto Brasileiro de Economia (IBRE/FGV) e do Banco Central do Brasil (BACEN).

A sazonalidade foi extraída por meio do filtro X-12 e as séries foram deflacionadas pelo Índice Geral de Preços Disponibilidade Interna – IGP-DI. Após esse processo, aplicamos o logaritmo natural nos dados. Escolhemos esse período para evitar os efeitos da mudança econômica ocasionadas pela implantação do Plano Real e por causa de outliers observados no setor agropecuário no ano de 1994

Por fim, conforme será discutido na próxima subseção, na medida em que a decomposição de *wavelet* é robusta a mudanças estruturais, *outliers* e não-estacionariedade, não é necessário aplicar testes usuais em séries temporais para verificar a presença de raiz unitária, quebra estrutural, entre outros.

2.3.2 Transformada de Wavelets (TW)

A TW é uma ferramenta que tem sido muito aplicada para realizar análises em tempo-frequência, apresentando resultados relevantes em diversas áreas do conhecimento, como na economia. Esta ferramenta possibilita uma análise simultânea de informações no domínio do tempo e da frequência com mais flexibilidade do que a correspondente representação de tempo-frequência da transformada de Fourier de tempo-curto (*Short-Time Fourier Transform* (STFT)).

⁴O subgrupo de índices de preços agropecuários (IPA-OG-DI) podem ser encontrados e disponíveis em: <https://www.fgv.br/mailling/2020/conjuntura-economica/01-janeiro/revista/68/#zoom=z> . O grupo de produtos agropecuários é subdividido em Lavouras Permanentes, Lavouras Temporárias e Pecuária.

⁵ Base monetária adicionada ao total de depósitos a prazo no sistema bancário, incluindo os Certificados de Depósito Bancário e Interbancário (CDB e CDI) e a parte dos títulos públicos (inclui apenas aqueles títulos que não estão em poder de bancos e de fundos de investimento).

A essência da ferramenta *wavelet* é fornecer uma melhor resolução no domínio do tempo, na medida em que as funções de base da *wavelet* são localizadas no tempo (ou escala), o que é útil para capturar a volatilidade variável do ciclo de negócios (YOGO, 2008). Define-se análise de multirresolução como uma sequência base de subespaços lineares encaixados e suas funções base são conhecidas como funções escalares. Em seguida, esses novos espaços complementares encaixados, denominam-se de funções *wavelets*.

2.3.3 Análise de Wavelet Multirresolução (MR)

A reconstrução da série temporal $x(t)$ com base na análise MR começa com um banco de filtros de reconstrução perfeita de dois canais: os filtros de análise dos filtros *lowpass* e *highpass*, definidos pela expressão $\{f_0(k)\}_{k=0}^{\tilde{N}}$ e $\{f_1(k)\}_{k=0}^{\tilde{N}}$, respectivamente. A função de escala da análise $\tilde{\phi}(t)$ é determinada pela equação de dilatação da análise, a seguir:

$$\tilde{\phi}(t) = \sum_{k=0}^{\tilde{N}} 2h_0(k)\tilde{\phi}(2t - k) \quad (1)$$

A transformada *wavelet* $\tilde{w}(t)$ é definida pela equação:

$$\tilde{w}(t) = \sum_{k=0}^{\tilde{N}} 2h_1(k)\tilde{\phi}(2t - k) \quad (2)$$

Sejam $\tilde{\phi}_{jk}(t) = 2^{j/2}\tilde{\phi}(2^j t - k)$ e $\tilde{w}_{jk}(t) = 2^{j/2}\tilde{w}(2^j t - k)$ as funções dimensionamento e *wavelet* na escala j e localização k . O j -ésimo nível da decomposição *wavelets* de um sinal contínuo temporal $x(t)$ é representado pela equação:

$$x(t) = \sum_k \tilde{\alpha}_{0k}\phi_{0k}(t) + \sum_{j=0}^{J-1} \sum_k \tilde{b}_{jk}w_{jk}(t) \quad (3)$$

Em que, $\tilde{\alpha}_{0k} = \int x(t)\tilde{\phi}_{0k}(t)dt$ e $\tilde{b}_{jk} = \int x(t)\tilde{w}_{jk}(t)dt$.

Definindo $H_0(w)$ e $H_1(w)$ como as respostas em frequência dos filtros *lowpass* e *highpass*, respectivamente, o filtro que relaciona os coeficientes de dimensionamento $\tilde{\alpha}_{0k}$ ao sinal original tem uma resposta em frequência dada por:

$$A_0(w) = \prod_{l=0}^{J-1} H_0(2^l w) \quad (4)$$

Desta forma, o filtro relacionado trata de um filtro *lowpass* com uma aproximação *passband* $|w| \in [0, \frac{\pi}{2^j}]$. De forma análoga, o filtro que relaciona o coeficiente *wavelet* \tilde{b}_{jk} a nível J , ao sinal original tem a resposta em frequência, a seguir:

$$B_j(w) = H_1(2^{J-j-1}w) \prod_{l=0}^{J-j-2} H_0(2^l w) \quad (5)$$

Que corresponde a um filtro *bandpass* com uma aproximação *bandpass* definido por $|w| \in [\frac{\pi}{2^{J-j}}, \frac{\pi}{2^{J-j-1}}]$.

Seja $F_o(w)$ a resposta em frequência do filtro síntese *lowpass*, note que quando $F_o(w)$ possui p zeros em π , a *wavelet* possui p momentos nulos. Dessa maneira, os polinômios de ordem $p - 1$ podem ser expressos como uma combinação linear das funções dimensionamento $\phi_{0k}(t)$. Para filtrar a tendência linear em séries econômicas não estacionárias, como por exemplo, preço agropecuários $p \geq 2$, é uma condição necessária na escolha do filtro *wavelet*.

2.3.4 Filtro Wavelet Biortogonal

Feita a análise MR, pode-se construir uma MR biortogonal. Dessa forma, quanto à família *orthogonal*, destaca-se o maior número de graus de liberdade para uma ampla gama de funções, além de ser uma escala mais eficiente para as baixas frequências, o que permite uma extração mais robusta da tendência estocástica das séries temporais.

O processo de estimação para analisar o comportamento temporal dos índices brasileiros em estudo, especificou-se que os ciclos filtrados devem possuir ao menos 6 meses de duração e não devendo perdurar mais do que 15 meses. A extração dos ciclos dos índices de preço agropecuários, índice geral de preços de mercado e oferta de moeda das séries temporais em análise será obtida a partir da decomposição *wavelet* em 5 escalas com distintas frequências.

Como $x(t)$ representa uma série temporal composta por um conjunto de dados mensal, a transformada de *wavelet* em 5 escalas irá decompor a série como:

$$x(t) = x_0(t) + \sum_{j=0}^5 y_j(t) \quad (6)$$

Em que $x_0(t)$ denota ciclos com periodicidade superior à 64 períodos (tendência estocástica) e $y_j(t)$ representa ciclos com periodicidade entre 2^{5-j} e 2^{6-j} períodos. Ou seja, $y_0(t), y_1(t), y_2(t), y_3(t)$ e $y_4(t)$ são os componentes de ciclos econômicos (periodicidade de

32-64, 16-32, 8-16, 4-8 e 2-4 meses, respectivamente). Para a construção dos ciclos serão acumuladas as variações entre 8 e 64 meses ($c(t) = y_0(t) + y_1(t) + y_2(t)$).

Desta forma, $y_3(t)$ e $y_4(t)$ correspondem a ruídos com periodicidade inferior a oito meses, o qual será expurgado da análise.

2.3.5 Identificação dos ciclos segundo Harding e Pagan (2002)

Com o propósito de identificar os períodos de expansão e recessão, inicialmente é necessário que se date os ciclos econômicos brasileiros em análise. Dessa forma, utiliza-se a metodologia proposta por Harding e Pagan (2002). Para identificar o comportamento dos ciclos de negócios, os autores mencionados apresentaram duas estatísticas que sincronizam os ciclos de negócios. A primeira corresponde ao índice de concordância que mensura a fração de tempo em que duas economias ou duas séries econômicas estão em um mesmo regime. A segunda diz respeito a uma medida de correlação, que mensura o grau em que os pontos de inflexão entre duas economias ocorrem uma próxima da outra.

Harding e Pagan (2002), para fazer a análise de detecção dos ciclos, expandem o algoritmo de Bry-Boschan (1971). Os autores buscam determinar pontos de máximo e mínimo ao longo de um dado intervalo temporal, uma vez que pares adjacentes de máximos (picos) e mínimos (vales) absolutos locais são selecionados como candidatos a representar os ciclos de negócios, passando a serem avaliados de acordo com um conjunto de regras.

Finalizando-se o processo de seleção do algoritmo, são considerados somente os pares adjacentes, em que a duração completa de um ciclo (pico a pico, vale a vale) possua no mínimo 18 meses e que cada fase de transição (pico a vale, vale a pico) tenha duração mínima de 6 meses.

Em termos algébricos, um pico em uma dada série mensal y_t ocorrerá no período t se:

$$\{(y_t - y_{t-6}) > 0, \dots, (y_t - y_{t-1}) > 0\} \text{ e } \{(y_{t+6} - y_t) < 0, \dots, (y_{t+1} - y_t) < 0\} \quad (7)$$

Assim, um vale ocorrerá se:

$$\{(y_t - y_{t-6}) < 0, \dots, (y_t - y_{t-1}) < 0\} \text{ e } \{(y_{t+6} - y_t) > 0, \dots, (y_{t+1} - y_t) > 0\} \quad (8)$$

Segundo Harding e Pagan (2002), um ciclo de negócios completo é composto por duas fases: a fase de recessão (do pico até o vale) e a fase de expansão (do vale até o pico). Entendendo as fases cíclicas, é possível analisar o comportamento dos ciclos de negócios através de um conjunto de medidas. As fases cíclicas, para o presente estudo, são classificadas por sua duração e amplitude.

Em relação à duração das fases, esta medida representa o grau de persistência dos períodos de contração e expansão. Em termos matemáticos, a fase de recessão (expansão) é igual ao número de meses entre o pico (vale) e o próximo vale (pico). A amplitude das fases é mensurada a partir da taxa de alteração em y_t a partir do pico [vale] (y_0) até o período em que o próximo vale [pico] é alcançado (y_k), o valor é dado em termos absolutos.

2.3.6 Teste de causalidade de Granger em um VAR bivariado

O teste de causalidade de Granger foi realizado com três variáveis, índice de preço agropecuário, índice de preço de mercado e política monetária. Formando a partir destes três pares: índice de preço agropecuário x índice de preço de mercado; índice de preço agropecuário x política monetária; índice de preço de mercado x política monetária. Sendo estimados Var(p) bivariados para cada par de variáveis. Portanto, o Var(p) é identificado através de uma decomposição de Cholesky na qual a ordenação causal é definida em conformidade com os resultados de testes de causalidade de Granger.

Conforme Enders (2010), por causa da endogeneidade das variáveis, estima-se o modelo Var(p) em sua forma reduzida. Suponha, por simplicidade, um VAR(1) bivariado estacionário com forma estrutural dada por:

$$\begin{bmatrix} 1 & b_{12} \\ b_{21} & 1 \end{bmatrix} \begin{bmatrix} Z_t \\ X_t \end{bmatrix} = \begin{bmatrix} y_{11} & y_{12} \\ y_{21} & y_{22} \end{bmatrix} \begin{bmatrix} Z_{t-1} \\ X_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \end{bmatrix} \quad (9)$$

Em que $\varepsilon_{1,t}$ e $\varepsilon_{2,t}$ são ruídos brancos. A correspondente forma reduzida é:

$$\begin{bmatrix} Z_t \\ X_t \end{bmatrix} = \begin{bmatrix} c_{11} & c_{12} \\ c_{21} & c_{22} \end{bmatrix} \begin{bmatrix} Z_{t-1} \\ X_{t-1} \end{bmatrix} + \begin{bmatrix} \mu_{1,t} \\ \mu_{2,t} \end{bmatrix} \quad (10)$$

Sendo que:

$$c_{11} = \frac{y_{11} - b_{12}y_{21}}{1 - b_{12}b_{21}}, \quad c_{21} = \frac{y_{21} - b_{21}y_{11}}{1 - b_{12}b_{21}}, \quad \mu_{1,t} = \frac{\varepsilon_{2,t} - b_{21}\varepsilon_{1,t}}{1 - b_{12}b_{21}},$$

$$c_{12} = \frac{y_{12} - b_{12}y_{22}}{1 - b_{12}b_{21}}, \quad c_{22} = \frac{y_{22} - b_{12}y_{12}}{1 - b_{12}b_{21}}, \quad \mu_{2,t} = \frac{\varepsilon_{2,t} - b_{21}\varepsilon_{1,t}}{1 - b_{12}b_{21}},$$

Para Marco e Cavalcante (2010), o VAR na forma reduzida resume as correlações observadas entre as variáveis de interesse e pode ser estimado sem problemas. Entretanto, o modelo VAR não permite identificar todos os parâmetros na forma estrutural, a não ser que imponha restrições adicionais. Este é o problema da identificação.

O VAR estrutural (1) identificado pelo método da “decomposição de Cholesky” baseia-se na imposição de duas restrições à forma estrutural: primeiro, considere que os choques estruturais não sejam correlacionados contemporaneamente, onde $E(\varepsilon_{1,t}\varepsilon_{2,t}) = 0$. Segundo, que

um dos coeficientes b_{12} ou b_{21} seja zero, o que equivale a impor uma ordenação causal contemporânea entre X e Z : sob $b_{12}=0$, Z não é afetada contemporaneamente por X , mas X é afetada por Z ; e sob $b_{21}=0$ ocorre o inverso.

Posto isso, o modelo é exatamente identificado e é possível proceder à investigação das interrelações entre as variáveis por meio de funções de resposta a impulso e decomposição de variância dos erros de previsão do modelo.

O método de identificação baseado na decomposição de Cholesky refere-se à escolha da ordenação causal das variáveis a escolha do coeficiente a ser zerado na matriz de relações contemporâneas do VAR estrutural (b_{12} ou b_{21}) pode ser o principal problema. Os testes de causalidade de Granger podem apontar quatro possibilidades: (i) causalidade unidirecional de Z para X ; (ii) causalidade unidirecional de X para Z ; (iii) causalidade bidirecional; (iv) ausência de causalidade em qualquer direção.

O coeficiente a ser zerado seria b_{12} sob (i) e b_{21} sob (ii); nos casos (iii) e (iv) não fica claro o procedimento a ser adotado, mas, aparentemente, em alguns estudos se verifica que os autores determinam a “ordenação causal” com base nos p -valores dos testes de causalidade de Granger. Portanto, considere, por exemplo, o teste de causalidade de Granger de X para Z . Note que a hipótese nula do teste pode ser definida em função dos parâmetros da forma estrutural: $H_0: c_{12} = \frac{\gamma_{12} - b_{12}\gamma_{22}}{1 - b_{12}b_{21}} = 0$

Suponha o teste em $\gamma_{12} - b_{12}\gamma_{22} = 0$, e não $b_{12} = 0$. A hipótese nula do teste pode ser rejeitada, ou não, independentemente de b_{12} assumir um valor nulo ou diferente de zero. Logo, a ausência de causalidade de Granger de X para Z não é condição necessária nem suficiente para a ausência de efeito contemporâneo de X sobre Z e que, portanto, esse procedimento está equivocado. Porém, não invalida totalmente note que a hipótese nula (3) seria verdadeira sob três situações básicas: 1. (a) $\gamma_{12} = 0$ e $b_{12} = 0$; 2. (b) $\gamma_{12} = 0$ e $\gamma_{22} = 0$; 3. (c) $\gamma_{12}, b_{12}, \gamma_{22} \neq 0$, sendo $\gamma_{12} = b_{12}\gamma_{22}$.

Suponha que em (a) a ausência de causalidade de Granger estivesse positivamente correlacionada com a ausência de efeito contemporâneo de uma variável sobre outra então seria possível argumentar que, apesar de teoricamente inadequado, o método de identificação sob análise poderia conduzir indiretamente, na prática, a conclusões corretas acerca da ordenação adequada do VAR. Entretanto, pelo menos dois problemas são identificados. Primeiro, se verificassem as igualdades $\gamma_{12} = 0$ e $b_{12} = 0$, então X não deveria ter nenhum efeito sobre Z , de modo que a resposta de Z a um choque em X deveria ser nula para qualquer horizonte de tempo;

isso não é, porém, o que ocorre na maioria dos estudos que empregam esse método de identificação⁶.

2.4 Resultados

As estatísticas descritivas das séries IPA-OG-DI, IGP-M e M2, na Tabela 1, mostram que os coeficientes mínimos em relação aos coeficientes máximos, em termos absolutos, são menores, indicando uma trajetória de crescimento para estes índices. Para o desvio padrão, M2 e IPA-OG-DI apresentaram respectivamente [0,0802; 0,1226], esses valores são muito acima de suas médias correspondendo respectivamente [0,0506; 0,0871], isso pode ser explicado pelo aumento da oferta de moeda (M2), que conseqüentemente pressionou o aumento do IPA-OG-DI. Uma visão mais ampliada desse cenário é mostrada no Gráfico 2.

Com relação às assimetrias, M2 é assimétrico à esquerda (distribuição com assimetria negativa). Porém, IPA-OG-DI e IGP-M são ambos assimétricos à direita (distribuição com assimetria positiva). Este resultado pode ser explicado pela adoção de uma política monetária restritiva, ou seja, uma redução da oferta de moeda para conter a inflação devido ao cenário de incerteza em que a economia se encontrava. Os índices M2, IPA-OG-DI e IGP-M têm distribuição leptocúrtica com caudas pesadas, apresentando picos de vários múltiplos acima da média, indicando uma trajetória de crescimento conforme apresentam as áreas sombreadas no Gráfico 2.

Tabela 1 – Estatísticas descritivas das séries em análise

	M2	IPA-OG-DI	IGPM
Média	0,051	0,087	0,074
Mediana	0,055	0,079	0,070
Máximo	0,274	0,420	0,285
Mínimo	-0,145	-0,210	-0,017
Desvio Padrão	0,080	0,123	0,055
Assimetria	0,085	0,219	1.262,242
Curtose	3.339.339	3.108.894	5.986.315

Fonte: Elaboração própria.

⁶ O VAR com três ou mais variáveis, mesmo que todos os coeficientes de X (contemporâneo e defasado) na equação de Z sejam nulos, é possível que um choque em X afete Z através de seu efeito sobre as demais variáveis do sistema. Continua sendo verdade, porém, que se X não causa Z no sentido de Granger e não afeta nenhuma variável do sistema contemporaneamente (isto é, X é a última variável na ordenação de Cholesky), então a resposta de Z a um choque em X deve ser nula para qualquer período de tempo.

Na Tabela 2, os resultados das estatísticas descritivas dos ciclos M2 e IGP-M mostram que os coeficientes mínimos em relação aos coeficientes máximos, em termos absolutos, são maiores, enquanto o IPA-OG-DI possui um coeficiente mínimo em relação ao coeficiente máximo, em termos absolutos, menor. Este fato caracteriza uma expansão de M2 e IGP-M podendo ser explicado da seguinte forma: numa situação de velocidade de circulação da moeda com o produto constante a curto prazo, qualquer elevação na quantidade de moeda significa elevação nos preços. Esse processo inflacionário no longo prazo pode ocasionar períodos de recessão econômica.

Os desvios padrão de M2, IPA-OG-DI e IGP-M têm valores muito acima da média. Essa trajetória de crescimento de IPA-OG-DI e IGP-M são explicados pela expansão de M2. Os ciclos desse cenário são apresentados no Gráfico 2. Em relação às assimetrias, todos os índices são assimétricos à esquerda, indicando uma política monetária mais rígida para minimizar os efeitos da inflação. Os índices M2, IPA-OG-DI e IGP-M têm distribuição leptocúrtica com caudas pesadas, indicando uma trajetória de recessão econômica conforme apresentam as áreas sombreadas no Gráfico 3.

Tabela 2 – Estatísticas descritivas dos ciclos em análise

	M2	IPA-OG-DI	IGPM
Média	-3,1E-18	-6,4E-18	-5,5E-18
Mediana	0,007	0,002	-0,002
Máximo	0,063	0,150	0,058
Mínimo	-0,094	-0,139	-0,061
Desvio Padrão	0,033	0,060	0,024
Assimetria	-0,391	-0,027	0,075
Curtose	2.566.009	2.720.315	2.684.385

Fonte: Elaboração própria.

Conforme apresentado no Gráfico 2, a evolução dos índices mensais dos preços gerais e dos preços agropecuários seguem em mesma direção⁷. Os períodos entre 2001-2005; 2009-2011 e 2014-2017, apontam períodos de maiores picos nos preços agropecuários. Entre o período 2001-2005 e 2009-2011 caracterizado pelos superciclos dos preços de *commodities* ou o efeito China, o aumento da demanda por esses produtos, especialmente agropecuários,

⁷ As séries de tempo são estacionárias segundo os testes de raiz unitária ADF e KPSS, conforme apresentado em anexo na Tabela A.1.1.

ocasionou o efeito-preço das exportações.⁸ Esse cenário também foi verificado pelo estudo de (BLACK, 2015).

No período de 2009-2011, a intensidade dos efeitos da crise financeira e o excesso de liquidez induziram a alta nos preços das *commodities*, tendo o mercado financeiro como o principal canal, pois os preços desses ativos tendem a aumentar, e como o comportamento nos mercados futuros influenciam a formação do preço no mercado *spot*, forma-se o canal pelo qual as atividades financeiras intervêm nos preços agrícolas e, por conseguinte, nos preços dos alimentos, conforme visto por Serigati (2012).

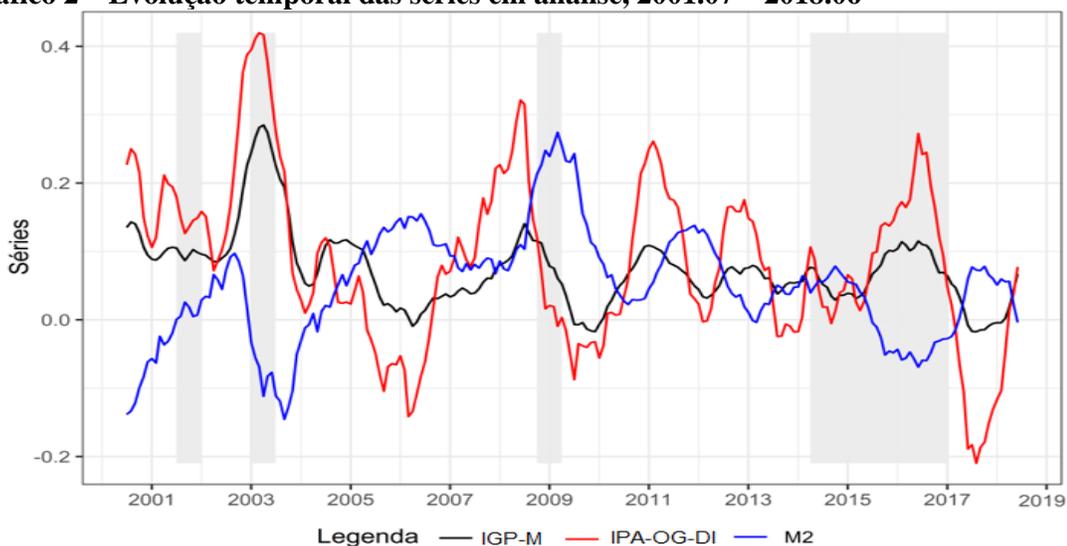
Entre o período 2005-2007 e 2008-2009, verificou-se uma forte desaceleração da inflação, devido à menor pressão dos preços das *commodities* no mercado internacional, em decorrência da desaceleração da economia mundial associada à crise econômica de 2008. O esfriamento da demanda doméstica, nesse período, pode ter contribuído para uma interrupção do ciclo de alta da taxa de juros básica conduzida pelo Banco Central do Brasil. Do lado da política monetária, pode-se observar um forte afrouxamento conforme mostra o gráfico 2.

É importante mencionar que de 2010 a 2014, no cenário econômico comumente chamado de *boom* das *commodities*, observou-se liderança na magnitude do índice dos preços agropecuários *versus* liderança da magnitude do índice de preços gerais. Medidas de política monetária contracionistas foram adotadas para conter o processo inflacionário explicado pelo cenário de pressão de demanda com a elevação do índice de preço geral impactando diretamente na renda do consumidor.

Para concluir, a evolução temporal dos preços de *commodities*, em especial os preços agropecuários, faz-se necessário contextualizar a participação da China na posição de maior consumidor das principais *commodities* agrícolas brasileiras. Segundo dados estatísticos do Comércio Exterior- ICOMEX divulgado pela Fundação Getúlio Vargas-FGV (2021), o aumento da participação do mercado asiático entre 2017 e 2018 foi de 21,8% para 26,8%, explicado por um crescimento de 35,2%, sendo que as três principais *commodities* exportadas que impulsionaram este aumento foram: soja em grão, petróleo bruto e o minério de ferro, explicando 82% das exportações brasileiras.

Nos últimos períodos, entre o final de 2018 e início de 2019, a dinâmica dos preços agropecuários incluiu, segundo ICOMEX (2021), as seguintes fases de cenários: as mudanças estruturais na oferta e na demanda global, com especial atenção dada ao efeito China.

⁸ Influenciando diretamente na renda e no produto, como também nos efeitos multiplicadores sobre o consumo e o investimento, uma vez, que as exportações são fonte de demanda (BLACK,2015).

Gráfico 2 – Evolução temporal das séries em análise, 2001.07 – 2018.06

Fonte: Elaboração própria.

Nota: datações brasileiras obtidas pelo CODACE/FGV.

A evolução temporal dos preços agropecuários motivou várias discussões, tanto na fase de expansão do superciclo quanto em sua desaceleração, conforme visto por (BLACK, 2015; IMF, 2015). As áreas sombreadas, apresentadas no Gráfico 3, correspondem a quatro períodos de recessão na economia brasileira (que reflete uma combinação de vários fatores). O primeiro período de recessão, entre 2001-2002, foi marcado pela alta dos preços das *commodities* agrícolas, em contexto de expansão excessiva da demanda em diversas economias. Tal fato está associado ao aumento no preço do petróleo e liquidez econômica, conduzindo a um cenário inflacionário caracterizado pela crise alimentar, conforme Schmidhuber (2020).

No segundo período, em 2003, o país atravessava uma recessão no primeiro semestre, motivado pela queda no ritmo das exportações líquidas do país. De acordo com Souza (2004), em 2000, o país apresentou um superávit de 1,6% do PIB para um déficit de 4,6% do PIB, em 2003, associado a uma desaceleração dos preços das *commodities*, especialmente das agrícolas.

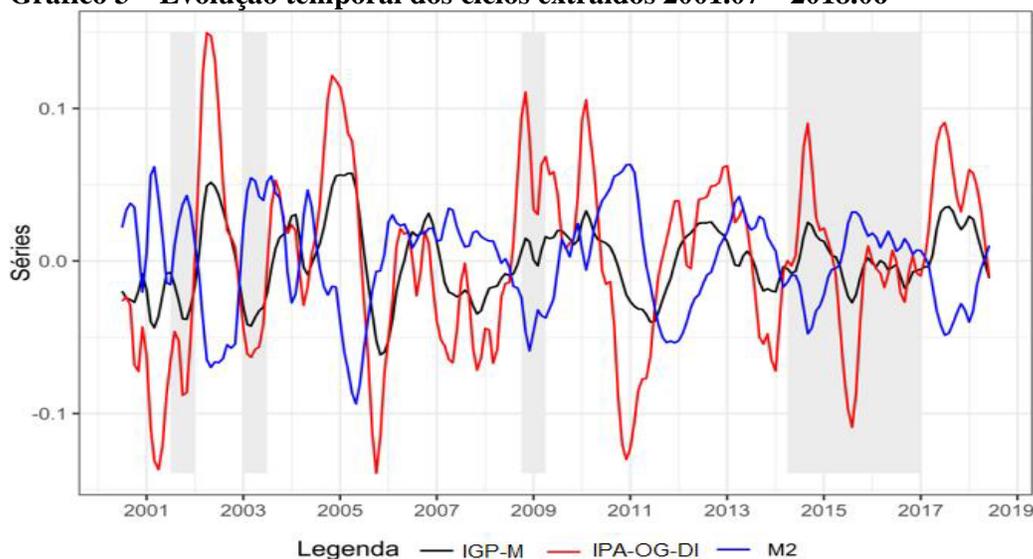
No terceiro período, entre 2008-2009, a trajetória inflacionária reflete uma certa combinação de vários fatores. Por exemplo, o aumento dos preços de energia e das cotações das *commodities* agrícolas, associada à expansão excessiva da demanda em várias economias, especialmente às emergentes, como é o caso da chinesa, umas das principais consumidoras das *commodities*. Estes fatores impulsionaram o aumento dos índices dos preços agropecuários e dos preços gerais, conforme apresentado no Gráfico 3. Após esse período, o processo de desaceleração inflacionária decorrente da crise financeira conduzindo a um cenário recessivo a volatilidade nos preços ficaram menos acentuada.

No quarto período de recessão, entre 2014-2016, o processo de desaceleração por parte das grandes economias associado aos efeitos da crise financeira influenciou diretamente a economia brasileira. O produto *per capita* brasileiro caiu cerca de 9% nesse período, portanto um conjunto de fatores levaram a economia brasileira a experimentar choques de oferta e demanda com as diretrizes da Nova Matriz Econômica (NME) do ano de 2011-2012; essas diretrizes correspondem a adoção de política monetária expansionista, de política fiscal para estimular os investimentos, concessões de subsídios e intervenção em preços (BARBOSA FILHO, 2017).

Importa mencionar que, em momentos de desaceleração inflacionária, a adoção de política monetária restritiva faz aumentar a oferta de moeda (base monetária) na economia, elevando a taxa básica de juros. Como consequência, a política monetária contracionista provoca a redução da produção e dos níveis de emprego. Em períodos de recessão, normalmente se adota uma política para estimular a economia através da redução da taxa básica de juros, ou seja, política monetária expansionista.

Segundo Barbosa Filho (2017), no ano de 2012, a condução da política monetária não foi tão eficaz para controlar a inflação no que diz respeito às diretrizes da (NME). A redução da taxa básica de juros, no cenário de inflação acelerada para estimular a economia devido à recessão, fez com que a taxa de inflação acelerasse (em níveis superiores ao aumento de preços), uma vez que reduziu a credibilidade da autoridade monetária. Esse resultado também pode ser verificado no Gráfico 3.

Gráfico 3 – Evolução temporal dos ciclos extraídos 2001.07 – 2018.06



Fonte: Elaboração própria.

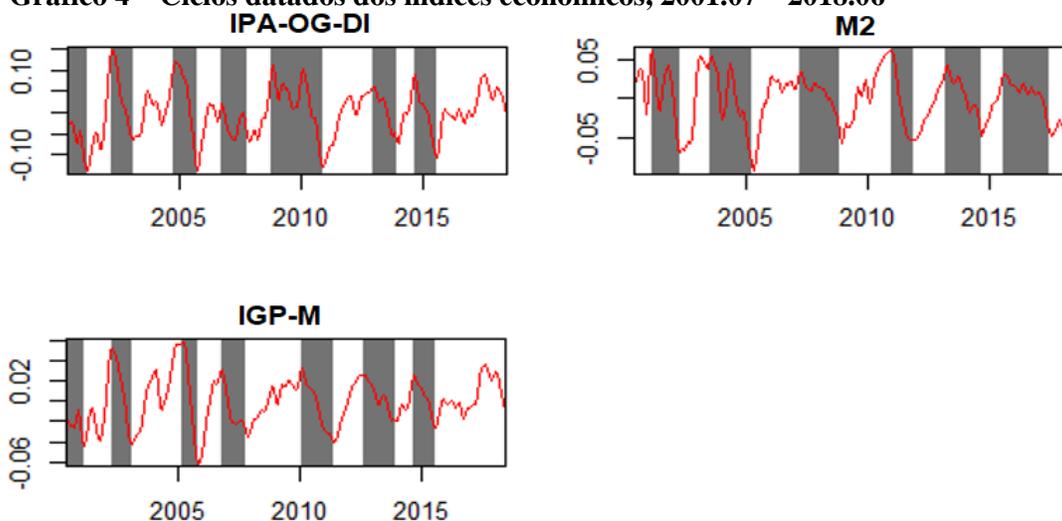
Nota: datações brasileiras obtidas pelo CODACE/FGV.

No Gráfico 4 são mostrados os ciclos datados dos índices econômicos do Brasil. As datações foram realizadas pelo algoritmo de Harding e Pagan (2002) para cada série associada. As áreas sombreadas indicam os períodos de fase de recessão nos ciclos de crescimento, iniciando-se em um máximo local (pico) até atingir o próximo mínimo local (vale).

No cenário que se apresenta, o número de recessões datadas possui similaridades entre o IPA-OG-DI e IGP-M, apresentando 7 períodos de recessão. Para M2, a quantidade de fases de recessão apresentou em 6 períodos. Inicialmente, pode-se identificar que apesar das datações serem parecidas, elas não são totalmente coincidentes. Identificou-se, de maneira geral, que a flutuação do IGP-M, correspondendo entre $[-0,06; 0,02]$, é similar à flutuação do IPA-OG-DI. Porém, este é mais errático, flutuando muito mais de $[-0,10; 0,10]$. Isso é natural porque estes indicadores de preços correspondem a uma média ponderada de vários fatores. Já os choques transitórios de M2 flutuam entre $[-0,05; 0,05]$, sendo menos errático, visto que nos períodos de recessão, medidas de política monetária expansionista, através da redução da taxa de juros básica, são utilizadas para estimular a economia.

Observando a relação da cronologia das variáveis, todas apresentaram ao menos uma fase de recessão no ciclo de crescimento durante os intervalos das crises 1 [2003.01; -2003.02], 3 [2005.01; -2005.02] e 6 [2014.02; -2016.04] as quais apresentaram recessão alinhada, conforme comentadas no Gráfico 4.

Gráfico 4 – Ciclos datados dos índices econômicos, 2001.07 – 2018.06



Fonte: Elaboração própria.

Conforme se depreende da Tabela 3, tanto a recessão quanto a expansão, os índices IPA-OG-DI e IGP-M oscilaram no mesmo período de duração. Porém, em relação à amplitude,

do ponto de vista individual, o IPA-OG-DI indica uma forte volatilidade, tanto nos ciclos de crescimento quanto de recessão, quando comparado com o IGP-M.

Em relação à persistência dos ciclos, as fases de expansão apresentaram a mesma média de duração correspondendo 18 períodos mensais para o IPA-OG-DI e IGP-M, indicando, em média, que os ciclos de expansão são mais duradouros. Já as fases de recessão apresentaram duração média de 12 períodos mensais para o IPA-OG-DI e IGP-M. Assim como no caso da duração média, os coeficientes de amplitude, das fases de expansão e recessão, apresentaram um padrão homogêneo, na maioria dos casos, indicando que os estágios de crescimento e contração nos ciclos de IPA-OG-DI e IGP-M são igualmente duradouros e severos.

Observando a persistência dos ciclos de M2, as fases de expansão e recessão apresentaram duração média de 18 períodos mensais. Vale ressaltar que as fases de recessão dos ciclos de M2 são mais duradouras quando comparadas com as fases de recessão do IPA-OG-DI e IGP-M. Por sua vez, os ciclos de M2 reportaram as menores taxas de amplitude, o que sugere uma trajetória estável nas suas respectivas flutuações. Já o IPA-OG-DI apresentou magnitudes superiores em ambas as medidas, indicando uma forte volatilidade nos ciclos de crescimento.

Este cenário pode ser explicado, conforme visto por Serigati (2012), o aumento significativo nos preços das *commodities*, especificamente as agrícolas, entre o período 2009 a 2011, estão ligados em parte ao mercado financeiro, visto que os preços desses ativos tendem a aumentar, e como o comportamento nos mercados futuros interfere na formação do preço no mercado *spot*, forma-se o canal pelo qual as atividades financeiras induzem os preços agrícolas e, conseqüentemente, influenciam os preços dos alimentos. Este cenário fica mais intenso quando há períodos de crise financeira associada a excesso de liquidez.

Tabela 3 – Médias dos ciclos, 2001.07 – 2018.06

	Duração da Recessão	Recessão	Expansão	Duração Expansão
IPA-OG-DI	12	0,034	0,047	18
IGP-M	12	0,005	0,012	18
M2	18	0,017	0,021	18

Fonte: Elaboração própria.

O teste de causalidade de Granger foi realizado com três variáveis: IPA-OG-DI, IGP-M e M2, sendo estimados Var(p) bivariados (teste em pares) para realizar o teste de Granger. A hipótese nula desse teste afirma que se uma variável Y “não causa no sentido de

Granger” outra variável Z, nesse sentido, Y não será útil para prever a variável Z. As variáveis são de periodicidade mensal e em primeira diferença, enquanto as defasagens foram selecionadas pelo critério de informação de Schwarz (até 12 defasagens).

Na Tabela 4 é verificado que se rejeita a hipótese de que o IPA-OG-DI não causa variações no ciclo (no sentido de Granger) do IGP-M, ao passo que também se verifica que o IGP-M não causa variações no ciclo (no sentido de Granger) do IPA-OG-DI, o que é exatamente o resultado esperado.

Se considerarmos um nível de significância de 1%, a relação de causalidade entre os ciclos do IPA-OG-DI e do IGP-M são bidirecionais. A relação causal da variação entre o IPA-OG-DI e o IGP-M precede a variação no IGP-M, indicando que o IPA-OG-DI capta a importância na determinação do IGP-M, dado que o IGP-M é utilizado para preservar as condições de locação diante das mudanças da economia, como a inflação. Entre a relação causal da variação do ciclo de M2 e do IGP-M, foi verificado que uma variação em M2 afeta diretamente o IGP-M. Também se verificou uma estrutura de realimentação entre expansão de M2 e do IGP-M. Se considerarmos um nível de significância de 1%, a relação de causalidade entre os ciclos de M2 e IGP-M são bidirecionais.

O teste de causalidade de Granger mostra a interação entre os ciclos de IPA-OG-DI e M2. A relação causal se estabelece em ambos os sentidos, ou seja, uma determinação recíproca entre IPA-OG-DI e M2.

Tabela 4 – Teste de causalidade de Granger

Hipótese Nula	Estatística F	p-valor
IPA-OG-DI não causa Granger IGP-M	9,800	0,000
M2 não causa Granger IGP-M	6,060	0,000
IGP-M não causa Granger IPA-OG-DI	2,360	0,030
M2 não causa Granger IPA-OG-DI	4,990	0,000
IGPM não causa Granger M2	2,310	0,033
IPA-OG-DI não causa Granger M2	3,230	0,004

Fonte: Elaboração própria.

Na análise das funções de resposta a impulso, testou-se o grau de resposta da variável IPA-OG-DI a variações (impulsos) de um desvio padrão do IGP-M e M2. No Gráfico 5 é apresentada a linha cheia que corresponde aos pontos estimados da função de resposta a impulso de cada IPA-OG-DI a impulso do IGP-M e M2 em unidade de desvio padrão. As linhas

tracejadas em vermelho denotam um intervalo de confiança de 95% construído a partir de 1000 replicações via *bootstrap*.

Conforme ilustrado no Gráfico 5, painel (a), observou-se que um choque positivo em M2 causa um aumento no IGP-M logo nos primeiros períodos, se estendendo do segundo ao décimo primeiro mês. Assim, um aumento de 1% em M2 causa um aumento de mesma magnitude no IGP-M no curto prazo.

Já no painel (b), quando ocorre um impulso no IPA-OG-DI a resposta do IGP-M, o efeito é significativo, ou seja, positivo nos primeiros períodos até o décimo segundo mês. Visto que um aumento de 1% no IPA-OG-DI causa um aumento de 0,5 % no IGP-M. Uma vez que o IPA-OG-DI tem um maior ruído branco (um sinal aleatório com igual intensidade em diferentes frequências), no curto prazo este afeta o IGP-M de maneira mais consistente.

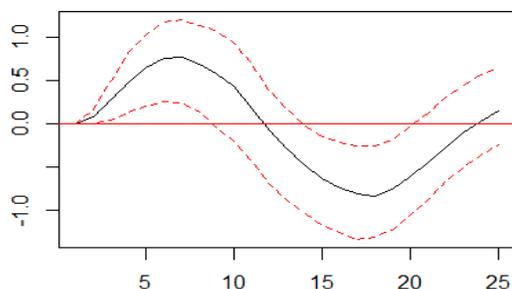
Para o painel (C) é verificado que o efeito do choque do IGP-M a resposta do IPA-OG-DI, não houve significância. Em relação ao painel (f), é visto que o efeito do choque do IPA-OG-DI à resposta da M2, primeiramente inicia de forma negativa, e após o vigésimo mês torna-se positivo. No longo prazo, o IPA-OG-DI afeta significativamente a política monetária; porém, não estabelece uma direção bem definida. O inverso pode-se observar no painel (d), onde um choque em M2 afeta o IPA-OG-DI de forma positiva no curto prazo, se estendendo do segundo ao décimo período. Entende-se que quando o governo reduz a oferta de moeda (política monetária restritiva), causa um efeito negativo sobre o IPA-OG-DI, ou quando o governo adota uma expansão da oferta de moeda (política monetária expansionista), ocorre um efeito positivo sobre o IPA-OG-DI.

Para o painel (e) observou-se que os efeitos de choques do IGP-M na resposta da M2, em ambos são recíprocos, demonstrando um padrão de resposta. Com relação ao IGP-M, este reage de forma positiva com o aumento da M2 e de forma negativa com a redução da M2.

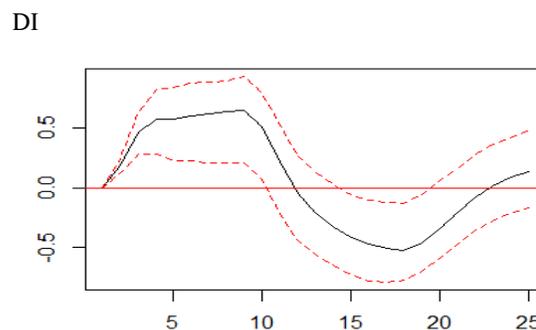
De forma geral, as explicações das respostas do IPA-OG-DI frente aos impulsos no IGP-M e M2, estão em conformidade com a literatura. Recordando a observação de Simonsen (1985), os preços das *commodities* alimentares são os maiores responsáveis pela elevação do índice geral de preços e que medidas de política monetária influenciam os preços das *commodities* alimentares de maneira mais intensa.

Gráfico 5 – Funções resposta ao impulso do Modelo VAR com as 3 variáveis (em pares)

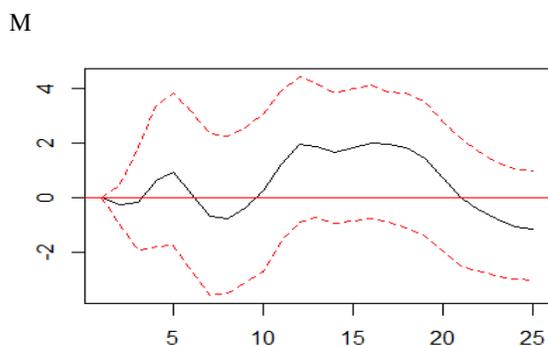
Painel a: Resposta do IGP-M ao Impulso em M2



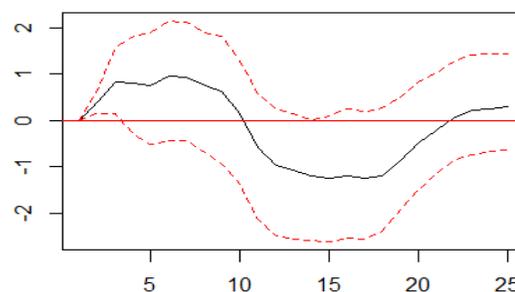
Painel b: Resposta do IGP-M ao Impulso em IPA-OG-



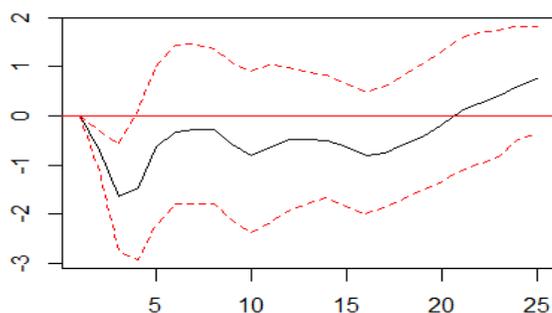
Painel c: Resposta do IPA-OG-DI ao Impulso em IGP-



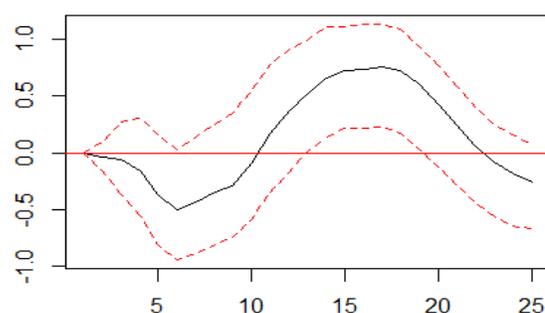
Painel d: Resposta do IPA-OG-DI ao Impulso em M2



Painel e: Resposta do M2 ao Impulso em IGP-M



Painel f: Resposta do M2 ao Impulso em IPA-OG-DI



Fonte: Elaboração própria.

Prosseguindo com a interpretação dos resultados, em relação à decomposição da variância, esta auxilia na compreensão das relações existentes entre as variáveis endógenas do modelo, mostrando o percentual de participação de cada variável na explicação da variância de uma determinada variável ao longo do tempo.

Pela Tabela 5, a decomposição da variância do IGP-M, logo no período inicial, não sofre nenhuma influência do IPA-OG-DI e de M2. Em relação ao longo prazo, o IGP-M possui forte interveniência sobre o IPA-OG-DI e M2. No sexto período, o IPA-OG-DI, possui uma

influência de 11% sobre o IGP-M, enquanto M2 induz 8% sobre o IGP-M, o que é bastante significativo. Importa mencionar que é o próprio IGP-M explica a sua variância em praticamente todo período de análise, apresentando um fator explicativo para a previsão da variância tanto de M2 quanto do IPA-OG-DI.

Ao analisar a evolução do IPA-OG-DI e IGP-M, este último é um indicador macroeconômico muito relevante para medir mensalmente o estado atual da economia e da inflação. Assim, o fato de o IGP-M explicar a sua variância, em praticamente todo período de análise, pode ser justificado pelas pressões de demanda⁹ ocorrida no período e controlada pela política monetária, principalmente quando se trata dos preços agropecuários.

O fato de M2 apresentar 8% de influência sobre o IGP-M, percebe-se que dado um cenário de expansão ou recessão econômica, a taxa de juros é o canal mais conhecido da política monetária para controlar a inflação. Um aumento da taxa de juros, por sua vez, tende a reduzir a demanda por bens e serviços da economia, contribuindo para a redução da inflação.

Tabela 5 – Decomposição da variância do IGP-M

Número de Períodos	IGP-M	IPA-OG-DI	M2
1	1,000	0,000	0,000
3	0,935	0,054	0,002
6	0,805	0,113	0,081
12	0,677	0,186	0,137
18	0,580	0,203	0,217
24	0,552	0,203	0,245

Fonte: Elaboração própria.

Conforme apresentado na Tabela 6, inicialmente, o IPA-OG-DI não sofre nenhuma influência em relação a M2; sendo que, ao longo do tempo, este é um fator pouco explicativo para a previsão do IPA-OG-DI. Em relação ao IGP-M, pode-se observar que ao longo do tempo, ele influencia significativamente tanto o IPA-OG-DI como a M2. A partir do décimo segundo mês, a decomposição da variância do IPA-OG-DI explica a sua variância em todo período de análise, o que se verifica sua autonomia em relação às demais variáveis no longo prazo.

⁹ as cotações da soja e do milho sofreram forte influência do efeito China, visto que esses são os principais produtos primários da pauta exportadora brasileira, o aumento da procura aumentou os preços desses produtos. Para Black (2015), o efeito China afeta diretamente o lado da demanda, conduzindo ao aumento nos preços das seguintes *commodities* agropecuárias: café, soja, milho e do boi gordo. Dado que esses são os principais produtos da pauta exportadora brasileira, o aumento da procura aumentou os preços desses produtos.

Tabela 6 – Decomposição da variância do IPA-OG-DI

Número de Períodos	IGP-M	IPA-OG-DI	M2
1	0,551	0,449	0,000
3	0,509	0,475	0,015
6	0,511	0,465	0,024
12	0,475	0,483	0,042
18	0,417	0,496	0,087
24	0,414	0,494	0,092

Fonte: Elaboração própria.

De acordo com a Tabela 7, verificou-se que no período inicial, M2 é pouco influenciado pelo IGP-M e IPA-OG-DI. Também se identificou que, no primeiro período, M2 explica a sua variância, sendo que no longo prazo não pode ser observado esse comportamento. O IGP-M apresenta um fator explicativo para a previsão da variação, tanto do M2 quanto do IPA-OG-DI, em todo período de análise.

Tabela 7 – Decomposição da variância do M2

Número de Períodos	IGP-M	IPA-OG-DI	M2
1	0,308	0,028	0,664
3	0,519	0,025	0,456
6	0,572	0,058	0,370
12	0,585	0,080	0,335
18	0,540	0,167	0,293
24	0,536	0,182	0,282

Fonte: Elaboração própria.

2.5 Conclusão

A assimetria dos ciclos dos preços da agropecuária tem ganhado espaço na investigação nos últimos anos. E, portanto, mesmo após um período de controle inflacionário, os níveis de preços no Brasil voltaram a se elevar no período recente. Os resultados mostram que a evolução temporal dos preços agropecuários, ao longo do período 2001-2018, especialmente nos períodos 2001-2005, 2009-2011 e 2014-2017, apresentaram uma forte expansão.

Entre o período 2001-2005, o cenário de inflação nos preços dos alimentos conduziu a um período de crise alimentar, conforme visto por Catão e Chang (2015). No contexto da crise global dos alimentos, é devido ao aumento do preço do petróleo, a partir de 2004. Já o período 2009-2011, a alta dos preços das *commodities* explicam em parte ao mercado financeiro, visto que os preços desses ativos tendem a aumentar, e como o comportamento nos

mercados futuros influencia a formação do preço no mercado *spot*, forma-se o canal pelo qual as atividades financeiras influenciam os preços agrícolas e, conseqüentemente, os preços dos alimentos, conforme visto por Serigati (2012).

Nos anos de 2014-2017, o superciclo dos preços de *commodities* ou o efeito China, o aumento da demanda por esses produtos, especialmente agropecuários, ocasionou o efeito-preço das exportações. Esse cenário também foi verificado pelo estudo de (BLACK, 2015). A forte desaceleração da inflação na economia brasileira foi verificada entre os períodos de 2005-2007 e 2008-2009, por conta de uma menor pressão dos preços das *commodities* no mercado internacional, em decorrência da desaceleração da economia mundial associada à crise econômica de 2008. O esfriamento da demanda doméstica, desse período, pode ter contribuído para uma interrupção do ciclo de alta da taxa de juros básica conduzida pelo Banco Central do Brasil, conforme visto por Serigati (2012).

Foram identificados quatro períodos de recessão na economia brasileira: o primeiro período de recessão (2001-2002) foi marcado pela alta dos preços das *commodities* agrícolas, em contexto de expansão excessiva da demanda em diversas economias, associado ao aumento no preço do petróleo e liquidez econômica, conduzindo a uma crise alimentar, conforme Schmidhuber (2020).

No segundo período (2003), o país atravessava uma recessão no primeiro semestre, motivado pela queda no ritmo das exportações líquidas do país. De acordo com Souza (2004), em 2000, o país apresentou um superávit de 1,6% do PIB para um déficit de 4,6% do PIB em 2003 associado com uma desaceleração dos preços das *commodities*, especialmente as agrícolas.

No terceiro período (2008-2009), a trajetória inflacionária reflete uma certa combinação de vários fatores, nomeadamente o aumento dos preços de energia e das cotações das *commodities* agrícolas, associado à expansão excessiva da demanda em várias economias, especialmente as emergentes, como é o caso da China, umas das principais consumidoras de *commodities*. Estes fatores impulsionaram o aumento dos índices dos preços agropecuários e dos preços de mercados. Após esse período, a volatilidade nos preços ficou menos acentuada.

No quarto período de recessão, entre 2014 e 2016, o processo de desaceleração por parte das grandes economias influenciou diretamente a economia brasileira. O produto *per capita* brasileiro caiu cerca de 9% (nesse período). Portanto, um conjunto de fatores levou a economia brasileira a experimentar choques de oferta e demanda com as diretrizes da Nova Matriz Econômica (MNE), do ano de 2011-2012. Essas diretrizes correspondem à adoção de

política monetária expansionista, de política fiscal para estimular os investimentos, concessões de subsídios e intervenção em preços (BARBOSA FILHO, 2017).

Os resultados das datações mostram que apesar de serem parecidas, elas não são totalmente coincidentes. O IPA-OG-DI é mais errático, flutuando muito mais que o IGP-M e M2. Em relação a amplitude, do ponto de vista individual, o IPA-OG-DI indica uma forte volatilidade tanto nos ciclos de crescimento quanto de recessão, quando comparado com o IGP-M.

Na análise da persistência dos ciclos, as fases de expansão apresentaram a mesma média de duração, correspondendo a 18 períodos mensais para o IPA-OG-DI e IGP-M, indicando, em média, que os ciclos de expansão são mais duradouros. A relação causal da variação, entre o IPA-OG-DI e o IGP-M, precede a variação no IGP-M, indicando que o IPA-OG-DI capta a importância na determinação do IGP-M, dado que o IGP-M é utilizado para preservar as condições de locação diante das mudanças da economia, como a inflação.

Entre a relação causal da variação dos ciclos de M2 e IGP-M, verificou-se que M2 afeta diretamente o IGP-M, apresentando uma estrutura de realimentação entre a expansão de M2 e o IGP-M. As explicações das respostas do IPA-OG-DI frente aos impulsos no IGP-M e M2 estão em conformidade com a literatura. No entendimento de Simonsen (1985), os preços das *commodities* agrícolas são os grandes responsáveis pela elevação do índice geral de preços e que medidas de política monetária influenciam os preços das *commodities* agrícolas de maneira mais intensa.

Pode-se verificar que o IGP-M explica a sua variância em praticamente todo período de análise. Isso pode ser explicado pelas pressões de demanda ocorrida no período, controlada pela política monetária principalmente quando se trata do mercado de *commodities*. O fato de M2 influenciar 80% do IGP-M, mostra que dado um cenário de incerteza econômica, a taxa de juros é o canal mais conhecido da política monetária para controlar a inflação. Assim, pode-se observar que o IGP-M apresenta um fator explicativo para a previsão da variação tanto de M2 quanto do IPA-OG-DI, em todo o período de análise.

3 ANÁLISE DAS LIGAÇÕES DOS PREÇOS AGROPECUÁRIOS E VARIÁVEIS MACROECONÔMICAS BRASILEIRAS: UMA APLICAÇÃO DO MODELO – FAVAR

A histórica escalada de preços das *commodities* agrícolas brasileiras, registrada logo após o período eleitoral, no ano de 2003, foi bastante peculiar. O processo de crescimento acelerado das economias ditas emergentes, especialmente a chinesa, possibilitou o aumento da demanda de produtos agrícolas, beneficiando a balança comercial brasileira, visto que a China é um dos principais parceiros comerciais do Brasil. Este foi um dos motivos para o aumento dos preços desses produtos.

Importa destacar que no período de *boom* das *commodities* (2003-2011), o Brasil registrou uma taxa média anual de crescimento econômico de 3,88%, muito relevante quando comparamos com o período do pós-*boom* (2012-2013); houve um desaquecimento das exportações agrícolas, uma vez que o Brasil registrou uma taxa de crescimento anual de 1,76%, conforme visto por Black (2015), e quedas significativas na taxa de crescimento econômico anual de 1,3% e de 1,1%, em 2017 e 2019, respectivamente (IBGE, 2020).

Diante desse cenário, os países que possuem maiores pauta de exportações desses produtos de origem primária, tiveram impacto direto nos termos de troca¹⁰ conduzindo a mudanças sobre a taxa de câmbio real e sobre os preços domésticos (SOARES *et al.*, 2016). Posto isso, alguns autores apontam que os preços agropecuários são indicadores úteis para prever a inflação (AWOKUSE, 2005; GOSPODINOV; NG, 2013, SOARES *et al.*, 2016).

Ademais, a formação de preços agropecuários pode estar relacionada à financeirização e aos fundamentos, como visto por Serigati (2012). O primeiro canal de transmissão corresponde à taxa de câmbio; com a desvalorização do dólar americano, os preços de todas as *commodities* agrícolas e minerais são influenciados diretamente por serem negociadas em dólar. Portanto, uma desvalorização desta moeda conduz a um aumento no preço desses produtos para manter seu valor real, o qual também pode ser explicado pela influência das atividades especulativas nos mercados de futuros¹¹.

O segundo canal de transmissão, conforme Serigati (2012), corresponde aos fundamentos ou mercados reais, em razão da lei da oferta e demanda, uma vez que a crescente

¹⁰ A explicação do termo de troca de um país pode ser compreendida pela variação dos preços dos produtos importados e exportados, conforme a participação de cada produto na estrutura comercial do país (BLACK, 2015).

¹¹ Segundo Serigati (2012), a atividade no mercado futuro através dos produtos agrícolas (ativos), com o aumento nos preços destes produtos, e como os movimentos nos mercados futuros influenciam a formação do preço no mercado *spot*, cria-se o canal pelo qual as atividades financeiras influenciam os preços agrícolas. Porém a formação dos preços agrícolas não se determina pelos mercados futuros, mas na combinação do lado real e financeiro da economia.

demanda por produtos como matérias-primas, principalmente no contexto de economias emergentes, tendo a China a principal consumidora e parceira comercial brasileira, o aumento da procura por esses produtos causou a alta dos preços desses produtos. No lado da oferta, o processo de inovação de máquinas e equipamentos (investimentos), as operações nos mercados financeiros, associado às alterações nas taxas de juros como arbitragem entre o mercado à vista e futuro, influenciaram diretamente nos preços das *commodities* (SOUZA, 2016).

Do ponto de vista de Anzuini *et al.*, (2013) e Gospodinov e Ng (2013), os preços agrícolas podem ser influenciados pela taxa de juros de curto prazo através de tomada de decisões dos investidores, uma vez que juros mais baixos incentivam um aumento na demanda dos investidores por ativos financeiros alternativos. Como os produtos agrícolas são mercadorias negociadas no mercado financeiro, o aumento da demanda por esses ativos aumenta os preços desses produtos.

A abordagem de Black (2015), para compreender a relação positiva entre variações nos preços agrícolas e taxa de crescimento econômico, é a seguinte: (a) efeito-preço nas exportações de *commodities*; (b) dos índices mensais das exportações de manufaturados para outros países exportadores de *commodities*; (c) resultados no emprego no setor explorador de recursos naturais; (d) possibilidade de se elevar as importações e, portanto, estimular a demanda doméstica e, por último, (e) o efeito nas receitas fiscais.

Convém salientar que o processo de expansão dos mercados agropecuários estabeleceu as bases para uma aproximação entre o comércio e o mercado financeiro. Com efeito, os preços agropecuários deixaram de responder somente aos estímulos de determinação de quantidade e preços dos produtos, conforme a lei de oferta e demanda, e também passaram a refletir a crescente conversão dos produtos agrícolas em ativos criados e negociados no mercado financeiro (BARBOSA FILHO, 2017).

Com base nesse cenário, são vários estudos que mostram um conjunto de fatores comuns que devem estar impulsionando os preços agropecuários. Logo, destaca-se que os preços agropecuários residem em sua grande importância tanto no contexto de geração de emprego e renda, como um importante impulsionador do crescimento econômico do país.

Nesse contexto, o presente estudo tem como objetivo geral analisar as ligações dos preços agropecuários e variáveis macroeconômicas brasileiras. Portanto, utilizou-se um modelo Vetor Autorregressivo Aumentado por Fator (Favar), proposto por Bernanke *et al.*, (2005). Do ponto de vista teórico, são poucos estudos brasileiros utilizando o modelo referido, para identificar as ligações entre os preços agropecuários com mais detalhes e controle de choques

macroeconômicos comuns. Assim, destaca-se um dos pontos relevantes do presente estudo na escolha deste modelo.

3.1 Introdução

Em termos gerais, através do Favar, um conjunto de séries desagregadas são estimadas via componentes principais, os fatores latentes em relação ao conjunto de preços de agropecuários, para em seguida inseri-los em uma especificação VAR conjuntamente com as variáveis macroeconômicas selecionadas. Desse modo, é possível realizar a inferência sobre a propagação de distúrbios no sistema de equações a partir das ferramentas tradicionais do modelo VAR, como a função impulso resposta.

3.2 Revisão da literatura

Nesta seção, foram selecionados alguns estudos sobre a relação entre os preços das *commodities* agrícolas e indicadores macroeconômicos. Em alguns deles são empregados, como ferramentas de análises, os métodos Vetoriais Autorregressivos, incluindo VAR recursivo e estrutural (SVAR), para capturar a relação entre os indicadores macroeconômicos sobre os preços desses ativos.

No entanto, estes modelos possuem restrições por utilizarem poucas variáveis, o que pode afetar a qualidade das evidências obtidas caso os choques desagregados específicos forem importantes. Os modelos de Vetores Autorregressivos Aumentados por Fatores Dinâmicos tentam tratar este problema, uma vez que nos permite analisar um grande número de variáveis macroeconômicas, que refletem melhor o conjunto de informações robustas usadas na tomada de decisões econômicas.

Awokuse (2005) e Anzuini *et al.*, (2013) objetivaram identificar o instrumento principal de política macroeconômica que afeta os preços agrícolas para as economias dos Estados Unidos através do mecanismo VAR. Awokuse (2005) mostra que no período de análise (1975-2000) as mudanças na oferta monetária têm pouca influência sobre os preços agrícolas. E que o principal instrumento de política macroeconômica que afeta os preços agrícolas é a taxa de câmbio, pois esta é influenciada pela taxa de juros, fonte de choques de política monetária.

Já Anzuini *et al.*, (2013) verificaram que uma política monetária expansionista ajuda a prever flutuações nos preços das *commodities* para a economia americana. Para o intervalo entre 2003 e 2008, as evidências obtidas indicam que choques de política monetária contribuíram para o aumento do índice de preços geral desses ativos e seus principais

componentes. No entanto, os autores ressaltam que choques de política monetária explicam apenas uma pequena parte do aumento no preço do petróleo.

Lanteri (2012) e Kim (2017) utilizam um SVAR para examinar determinantes de matéria-prima (preços agrícolas), econômicos (índice de estoque) e fatores macroeconômicos (crescimento industrial, política monetária e taxa de câmbio), para as economias dos Estados Unidos e Coreia do Sul. Com base nesse modelo, Lanteri (2012) observa que o crescimento industrial, políticas monetárias expansionistas, desvalorização cambial e redução de estoques são indutores para o aumento dos preços das *commodities* agrícolas para a economia dos Estados Unidos. A partir da mesma abordagem, Kim (2017) evidencia uma menor exposição dos preços agrícolas reais na Coreia a distúrbios macroeconômicos, se comparado com a economia dos Estados Unidos. O autor sustenta que a política de estabilização de preços e a forte regulação do mercado agrícola na Coreia do Sul são fatores preponderantes para o resultado apurado.

Soares *et al.*, (2016) examinam o comportamento dos preços internacionais de *commodities*, taxa de câmbio, taxa de juros, índice de preço ao consumidor e PIB brasileiro entre o período de 2003 a 2013, com base no modelo VAR. Os resultados indicam que os preços internacionais de *commodities* e o PIB têm efeito positivo sobre o índice de preço ao consumidor com um período de defasagem;¹² o aumento do câmbio tem um impacto negativo na inflação também com um período de defasagem¹³.

Souza *et al.*, (2015) investigam a relação das variações nos preços das *commodities* agrícolas brasileiras com as variáveis taxa de juros, taxa de câmbio, PIB e inflação esperada, entre o período de 2001 a 2012. Os resultados do modelo VAR indicam que a dinâmica da inflação é impactada pela própria inflação, inflação dos alimentos e expectativas inflacionárias, assegurando caráter inercial do aumento de preços.

Sun e Kuhelika (2019) examinam os efeitos da depreciação da taxa de câmbio no PIB dos EUA usando o modelo Favar correspondente ao período de 1973 pós-Bretton Woods a 2017. Os autores revelam que a escolha do modelo é viável pelo fato de resumir as informações de muitos dados de preços desagregados agrícolas (alimentos) em uma estimativa de índices de preços agrícolas ou fator latente e estudam seus efeitos dinâmicos em resposta a

¹² Os sinais das variáveis estão de acordo com o esperado, por outro lado, a taxa de juros e câmbio, causa efeito negativo na atividade econômica. Quando a economia está aquecida, a inflação tende a aumentar e como medida de controle, o governo aumenta a taxa de juros, a qual encarece os empréstimos, portanto, desestimula os investimentos e retrai a economia.

¹³ Dado que o Brasil é um exportador de *commodities* agrícolas, a desvalorização da taxa de câmbio deve impactar negativamente a taxa de inflação.

choques de política monetária. Os resultados indicam que choque cambial (depreciação) causa choque positivo para a economia americana, ocasionando melhora na conta corrente, ao longo do tempo, segundo a teoria da curva-J, e a intervenção da política monetária está inclinada contra o vento.

Fernald *et al.*, (2014) examinam um amplo conjunto de indicadores econômicos chineses em uma estrutura Favar para estimar o PIB e a inflação como variáveis latentes. Os autores apontam que o modelo Favar é particularmente adequado para o estudo, pois oferece um meio parcimonioso para incorporar um conjunto amplo de variáveis sem perder graus de liberdade.

Os resultados mostram que aumentos nas exigências de reservas bancárias reduzem o PIB e a inflação, enquanto outras medidas de mudanças nas condições de crédito como choques nos níveis de M2 ou de empréstimos, não são levadas em consideração. E que os canais de transmissão da política monetária na China mudaram e estão próximos das economias de mercado ocidentais.

Lombardi *et al.*, (2012) estudam as ligações entre a evolução dos preços das *commodities* não energéticas por meio de um modelo Favar. Os autores mostram que as funções de resposta a impulsos confirmam que a taxa de câmbio e o PIB afetam os preços individuais de *commodities* não energéticas. Por outro lado, não foram encontrados transbordamentos robustos dos preços das *commodities*, exceto o petróleo, ou um impacto na taxa de juros. E que os preços de *commodities* individuais são afetados por tendências comuns capturadas pelos fatores de alimentos e metais.

Balcilar (2016) investiga a relação entre os preços do petróleo e das *commodities* agrícolas na África do Sul. Os autores aplicam o teste não paramétrico da causalidade de Granger em quantis, a partir de dados diários de 19 de abril de 2005 a 31 de julho de 2014. Os resultados mostram que o impacto das variações do preço do petróleo nos preços das *commodities* agrícolas diferem em toda a distribuição condicional. O maior impacto está na faixa intermediária da distribuição condicional, mas não necessariamente a mediana. Os autores concluem que políticas para estabilizar os preços agrícolas da África do Sul devem considerar a evolução dos mercados mundiais de petróleo.

Chen e Tsang (2018) examinam como os choques externos são transmitidos aos diferentes setores da economia de Hong Kong, usando um modelo Favar. Os resultados sugerem que o efeito combinado da normalização da política monetária dos EUA e as políticas de flexibilização quantitativa em grande escala do Banco Central Europeu e do Japão podem

ter impactos adversos no setor real de Hong Kong, os quais poderiam ser significativamente reforçados com a desaceleração do crescimento da China continental.

Zuniga (2011) estuda a transmissão da política monetária dos EUA para o México e o Brasil com base no modelo Favara. Os resultados indicam que a taxa de juros é o principal canal de transmissão entre as economias. No caso do México, a taxa de juros induz grande resposta nas várias variáveis macroeconômicas. Já no Brasil, esse se beneficia levemente dos choques monetários contracionistas dos EUA.

Rosoiu (2015) faz uma análise de como as mudanças nas taxas de juros estão afetando o aumento da inflação e da taxa de desemprego na economia da Romênia, através do modelo Favara com base em 92 variáveis no modelo¹⁴, entre 2000 e 2013. Os resultados mostram que com o aumento do nível da taxa de juros, o nível da taxa de inflação diminui, independentemente do número de fatores. Por outro lado, a taxa de desemprego aumenta uma vez que o nível da taxa de juros é aumentado. Ao comparar com a resposta da taxa de inflação, a taxa de desemprego parece ser mais sensível ao número de fatores que foram escolhidos.

Kapuscinski (2017) aplica o modelo Favara com coeficientes variantes no tempo para identificar os efeitos de choques de política monetária sobre várias variáveis macroeconômicas na Polônia. Os resultados mostram que o aperto da política monetária tem efeitos contracionistas na atividade real e inflação. Os preços domésticos respondem aos preços globais de *commodities* e aos preços no exterior. No que diz respeito às implicações políticas, o estudo confirma que a política monetária afeta a inflação na Polônia.

Tan *et al.*, (2017) examinam o impacto da política monetária sobre o preço agrícola na China entre os períodos (2005-2016) através do modelo Favara. Os autores verificam que a política monetária tem forte influência sobre os preços agrícolas no curto prazo. Já no horizonte de longo prazo (além de 50 meses), tanto a oferta monetária quanto a taxa de juros não exercem impacto sobre os preços agrícolas. A margem de erro de previsões de longo prazo mostra que a taxa de juros é a principal variável causadora da volatilidade nos preços agrícolas.

3.3 Metodologia

¹⁴ O modelo Favara inclui dados como índices de preços ao produtor, agrupados por atividades principais: indústria, mineração e pedreiras, manufatura e eletricidade. Índices de preços ao consumidor, taxas de câmbio, taxas de juros, agregados monetários, número de pessoas empregadas, salários brutos e índices de volume de produção. Todas as variáveis são usadas para extrair os fatores e mais três séries são incluídas como variáveis independentes na seguinte ordem: taxa de inflação, taxa de desemprego e taxa de juros da política monetária. Os resultados estão de acordo com a literatura.

A frequência dos dados é mensal e o período analisado vai de janeiro de 2004 a julho de 2018. Para obter os fatores dinâmicos do modelo Favar, foram utilizadas 175 observações; as séries macroeconômicas correspondem ao índice de preços agropecuários disponibilizadas pelo Índice de Preços por Atacado (IPA-OG-DI)¹⁵, o Índice Nacional de Preços ao Consumidor Amplo (IPCA) e a Taxa de Câmbio Real Efetiva ambos extraídos do Instituto de Pesquisa Econômica Aplicada (IPEA)¹⁶; a Taxa de Juros Real Efetiva e o Índice de Atividade Econômica do Banco Central (IBC-Br)¹⁷ foram coletados pelo Banco Central do Brasil. O índice de preços Petróleo bruto (petróleo) foi disponibilizado pelo Fundo Monetário Internacional (FMI).

Neste estudo, o IBC-Br é utilizado como uma *proxy* para o PIB. O Índice de Incerteza Econômica brasileiro foi extraído com base na principal medida de incerteza econômica adotada, equivalente ao índice de incerteza político-econômico (EPU),¹⁸ tal qual desenvolvido por Baker *et al.*, (2016). Este índice é calculado pelo Instituto Brasileiro de Economia (IBRE), da Fundação Getúlio Vargas (FGV), que também sintetiza a informação contida em diversas *proxies* de incerteza.

Para verificar a estacionariedade das séries, foi utilizado o teste Dickey Aumentado Teste Fuller (ADF). Uma vez que as séries são estacionárias, elas são padronizadas e utilizadas na análise de componentes principais para extrair os fatores e as funções de resposta ao impulso são estimadas. Para isso, utilizou-se o software Eviews, versão 8.0, e o software R, versão 3.0.1, para a obtenção dos resultados econométricos.

3.3.1 Modelo Autorregressivo Vetorial Aumentado por Fator (Favar)

Este modelo permite uma análise econométrica conjunta das ligações entre todas as séries. E permite um amplo conjunto de séries, visto que é inviável em uma estrutura VAR tradicional. Como meio de reduzir a dimensionalidade do problema, empregou-se fator análise

¹⁵ O subgrupo de índices de preços agropecuários (IPA-OG-D) pode ser encontrado em: <https://www.fgv.br/mailling/2020/conjuntura-economica/01-janeiro/revista/68/#zoom=z>. Dentro do subgrupo dos índices de preços agropecuários, utilizou-se os índices dos produtos (classificados como lavouras temporárias e permanentes).

¹⁶ Para mais informações, ver: <http://www.ipeadata.gov.br>.

¹⁷ O IBC-Br é um indicador mensal que procura, com as devidas adaptações, a composição do Produto Interno Bruto (PIB) e o ambiente macroeconômico do país.

¹⁸ Importante destacar três considerações sobre as medidas de incerteza com base nos jornais Folha de São Paulo, seguindo a metodologia de Baker *et al.*, (2016).

1 Os dados compõem exatamente o Economic Policy Uncertainty (EPU) Index do Brasil, disponível na página <http://www.policyuncertainty.com>; 2. A série de incerteza é obtida pela frequência de notícias que trata de incerteza de política econômica; 3. Por se tratar de uma medida baseada no acervo online do jornal, atualizações retroativas deste acervo podem gerar pequenas variações na série ao longo do tempo.

usando um VAR com fator aumentado (Favar), conforme proposto por Bernanke *et al.*, (2005), ao mesmo tempo que mantém uma especificação VAR parcimoniosa para analisar as ligações entre fatores relacionados a preço agropecuários e indicadores macroeconômicos.

Denota-se o vetor contendo indicadores macroeconômicos e o conjunto completo de preços de log de *commodities*, como sendo X_t . Assumindo preços I (1), examina-se suas diferenças logarítmicas, ΔX_t . Já que aqui se trabalha com um grande conjunto de *commodities*, o tamanho N de X_t será significativo, o que impossibilitaria a estimativa do VAR.

$$\Delta X_t = \Phi(L) \Delta X_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim N(0, \Omega). \quad (11)$$

Agora, assuma que uma *commodity* de cada vez e colete os preços agropecuários sob análise e as variáveis macroeconômicas em um vetor Y_t de tamanho M. Uma vez que apenas uma *commodity* aparece em Y_t , M será muito menor do que N. Para resumir a evolução em outros preços de *commodities* que podem de fato ser relevantes, emprega-se uma medida reduzida, ou seja, um conjunto de K fatores não observáveis F_t . Portanto, estima-se o VAR.

$$\begin{bmatrix} \Delta Y_t \\ F_t \end{bmatrix} = \Phi(L) \begin{bmatrix} \Delta Y_{t-1} \\ F_{t-1} \end{bmatrix} + \mu_t, \quad \mu_t \sim N(0, Q), \quad (12)$$

Em que (L) é um polinômio de ordem finita no operador de defasagens. Notoriamente, se os termos de (L) relacionando ΔY_t para F_{t-1} forem zero, o sistema é um VAR padrão em ΔY_t . Caso não seja, omite-se F_t do sistema que resultará em estimativas viesadas. A equação 12 não pode ser estimada diretamente, pois os fatores F_t não são observados. Assim, é possível construir fatores de antemão, usando qualquer esquema de extração de fator, e então apenas inseri-los na equação (11) como se fossem variáveis observáveis.

Dessa forma, se assume que os elementos do vetor X_t são I, poder-se-ia expressar o modelo (11) na forma de correção de erro, como a seguir:

$$\Delta X_t = \alpha \beta X_{t-1} + v_t, \quad (13)$$

ou na especificação de tendências comuns conforme,

$$X_t = \psi F_t + \omega_t, \quad (14)$$

Sendo que F_t é o fator comum dinâmico. Se extrairmos um sub-vetor de X_t contendo apenas um preço de *commodities*, a equação (4) pode ser expressa da seguinte forma:

$$X_t = \begin{bmatrix} Y_t \\ Z_t \end{bmatrix} = \begin{bmatrix} \psi_Y \\ \psi_Z \end{bmatrix} F_t + \omega_t, \quad (15)$$

uma vez que Y_t e F_t são cointegrados. Pode-se, portanto, representar seu comportamento comum com uma especificação de correção de erro, como segue a equação:

$$\begin{bmatrix} \Delta Y_t \\ \Delta F_t \end{bmatrix} = \begin{bmatrix} \gamma_Y \\ \gamma_F \end{bmatrix} \delta \begin{bmatrix} Y_{t-1} \\ F_{t-1} \end{bmatrix} + e_t; \quad (16)$$

Sendo que γ e δ desempenham o mesmo papel que α e β na equação (13) e que mais defasagens podem ser adicionadas, a fim de eliminar e_t da autocorrelação. Nesse sentido, como o Favar, também o FAVECM visto em (16) pode ser facilmente estimado em duas etapas: os fatores são extraídos por meio de qualquer técnica padrão (por exemplo, componentes principais) e, em seguida, plugados no modelo de correção de erro.

3.4 Resultados

Foram extraídos três fatores para identificarmos como tendências comuns em um modelo Favar juntamente com as variáveis macroeconômicas selecionadas. Na Tabela A.2.1 (Apêndice) são apresentados os resultados do teste de raiz unitária ADF para os itens que compõem o segmento de produtos agropecuários do IPA-OG-DI, bem como as variáveis macroeconômicas utilizadas e os fatores posteriormente estimados a partir da estratégia empírica. Tanto os itens agropecuários quanto as variáveis macroeconômicas foram transformados em taxa de crescimento com relação ao mesmo mês do ano anterior. Conforme pode ser observado na Tabela A.2.1, em todos os casos, o teste ADF rejeita a hipótese nula de raiz unitária a um nível de 5% de significância.

A Tabela A.2.2 (Apêndice) apresenta as correlações das contribuições de cada fator de preços agropecuários. Os valores que estão em destaque representam de forma significativa a contribuição de cada fator. Como se pode observar, os fatores F1 e F3 possuem correlação forte com os grupos de *commodities* de lavouras temporárias e com o grupo pecuária. Identificou-se que o fator 3 possui uma correlação forte negativa com a cana-de-açúcar do grupo de lavouras temporárias.

Em particular, o fator 2 tem uma correlação forte positiva com apenas algodão do grupo de lavouras temporárias e pouca correlação com os demais produtos. Em resumo, pode-se observar que os resultados das correlações dos grupos de *commodities* agropecuárias mais representativos são as de lavouras temporárias e a pecuária. O que pode ser explicado pelo crescimento das exportações chinesas de grãos e carne bovina, tendo o Brasil como seu principal parceiro comercial desses produtos.

No contexto da produção de biocombustíveis, os preços das *commodities* (cana-de-açúcar, soja, mandioca e o milho) são alguns produtos que tiveram forte contribuição nos resultados das correlações dos fatores, ressaltando que, em especial, o milho é um dos produtos mais solicitados pelo mercado asiático, especialmente o chinês.

A Tabela A.2.3, na matriz de correlação dos resíduos, mostra que os erros de previsão são baixos oscilando entre (-0,175 e -0,031) com exceção da variável índice de atividade econômica que corresponde a (0,775). Isso revela que o ordenamento entre as variáveis não deve surtir muito efeito importante sobre a identificação da função de impulso resposta e decomposição da variância conforme abordagem de Enders (2010).

3.4.1 Funções de Impulso Resposta (FIR)

As funções de impulso resposta viabilizam a análise da resposta em uma variável de qualquer série, dado um impulso em qualquer outra variável da série, ou seja, permite identificar choques inesperados que influenciam as variáveis da série. Mais especificamente, a função impulso resposta explica o choque em uma variável em um período de tempo, assim como a duração necessária até a variável voltar a sua trajetória inicial.

O Gráfico 6 mostra a resposta da taxa de câmbio aos choques de um desvio padrão das nove variáveis macroeconômicas. Em relação à taxa de juros, um choque na taxa de juros contrai a taxa de câmbio entre 10% e 20%, num horizonte de 10 meses. Isso pode ser explicado, pelo lado dos preços de *commodities*, visto que a queda na taxa de juros causa um aumento nos preços das *commodities*, uma vez que, os investidores trocariam os títulos por *commodities* (consideradas como ativos financeiros). Esse aumento produz movimentos na taxa de câmbio real de um país na medida que esta mudança altera os termos de troca desse país.

Choques na própria taxa de câmbio tem uma persistência positiva durante todo o período. A taxa de câmbio também responde positivamente a choques no índice de atividade econômica e na inflação. Explicando pelo lado das exportações brasileiras, especialmente de *commodities* agrícolas, à medida que aumenta a receita de exportação, aumenta o valor das exportações, apreciando a taxa de câmbio, visto que esse movimento causa uma redução no volume exportado. Caso o efeito líquido seja positivo, haverá um aumento da renda nacional e da demanda agregada que, conseqüentemente, aumenta a produção, o emprego e o nível de preços conforme visto por Arruda (2008).

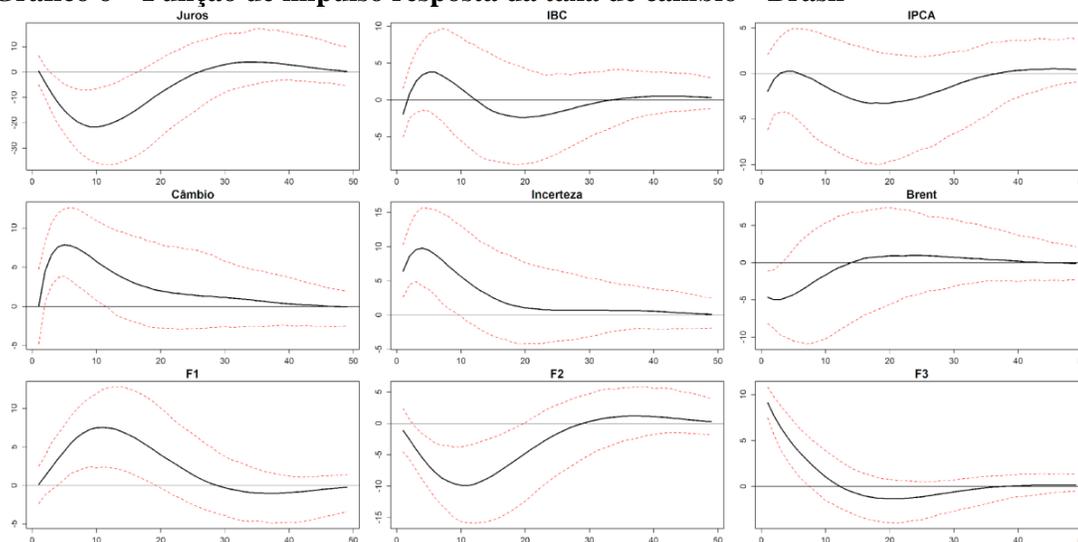
O impacto do índice de incerteza econômica na resposta da taxa de câmbio é positivo e significativo, entre 5% e 15%, num horizonte de 10 meses. A este resultado é possível conectar as preocupações com a incerteza das políticas governamentais que se intensificaram de forma global, fatores como turbulência econômica da crise financeira global e as crises contínuas na zona do euro contribuíram para um ambiente político tumultuado e futuro incerto, especialmente no Brasil.

Choques do petróleo (Brent) contrai a taxa de câmbio entre 5% e 10%, num horizonte de dez meses. A volatilidade dos preços internacionais do petróleo é uma variável importante para a determinação da taxa de câmbio. Observa-se uma correlação negativa entre esses dois ativos financeiros conforme visto por Silva *et.al.*, (2016). Há impactos positivos e estatisticamente significativos em dois dos três fatores relacionados com os preços das *commodities* agropecuárias. Dado um impulso de um desvio padrão nos fatores F1 e F3, a taxa de câmbio responde positivamente.

Isto é compreensível pela forte correlação entre esses fatores de grupo de lavouras temporárias e de grupo pecuária, por exemplo: arroz, milho, trigo, soja, feijão, algodão, cana-de-açúcar e carne de frango *in natura* entre outros. O crescimento da demanda por esses produtos, tendo a China como um dos principais compradores e consumidores, impulsiona o aumento nos preços dessas *commodities* que tende a ser atenuado pela apreciação cambial. Esses resultados coincidem com Martinez (2011), uma vez que a valorização do câmbio real reflete em parte os ganhos no valor das exportações com o aumento dos preços de *commodities* agropecuárias.

Já em relação a F2, esse fator de *commodity* possui forte correlação com o algodão e carne bovina *in natura*. Um choque no F2 contrai a taxa de câmbio por um curto período, o aumento dos preços dessas *commodities* provoca desalinhamentos na taxa de câmbio durante todo o período, sem uma tendência ao retorno da trajetória.

Gráfico 6 – Função de impulso resposta da taxa de câmbio – Brasil



Fonte: Elaboração própria¹⁹.

¹⁹ Observação: a linha contínua indica a resposta média estimada. As linhas tracejadas representam os intervalos de confiança de *bootstrap* de 68%, e as linhas pontilhadas representam os intervalos de confiança de *bootstrap* de 90%, com base em 1000 amostras de *bootstrap*. Todos os gráficos estão em padrão unidades de desvio.

As respostas da inflação aos choques de um desvio padrão das nove variáveis macroeconômicas estão descritas no Gráfico 7. Há impactos positivos, e estatisticamente significativos, em oito das nove variáveis. A inflação responde de início positivamente a taxa de juros, a taxa de câmbio, o índice de atividade econômica e o preço do petróleo Brent e aos preços dos fatores, além de choques na própria inflação. Em todos os casos, após essa resposta inicial, há uma variação em torno da trajetória original até a estabilização.

Como as *commodities* agropecuárias lideram a pauta de exportação brasileira e cuja receita oriunda da exportação é substancial para o fluxo de divisas do país. Verificou-se impactos similares da taxa de câmbio e da taxa de juros em resposta à inflação, evidenciando que a apreciação da taxa de câmbio pode ser em parte decorrente do aumento dos preços das *commodities* no mercado internacional, cujos ganhos, nos termos de troca, poderão influenciar o aumento da taxa de juros reais.

A inflação também responde positivamente aos choques do petróleo Brent, assim como os preços das *commodities* agropecuárias, o preço do petróleo Brent possui um peso importante na composição do IPCA como também exerce efeitos diretos e indiretos sobre os preços das *commodities* agropecuárias refletidos no IPCA.

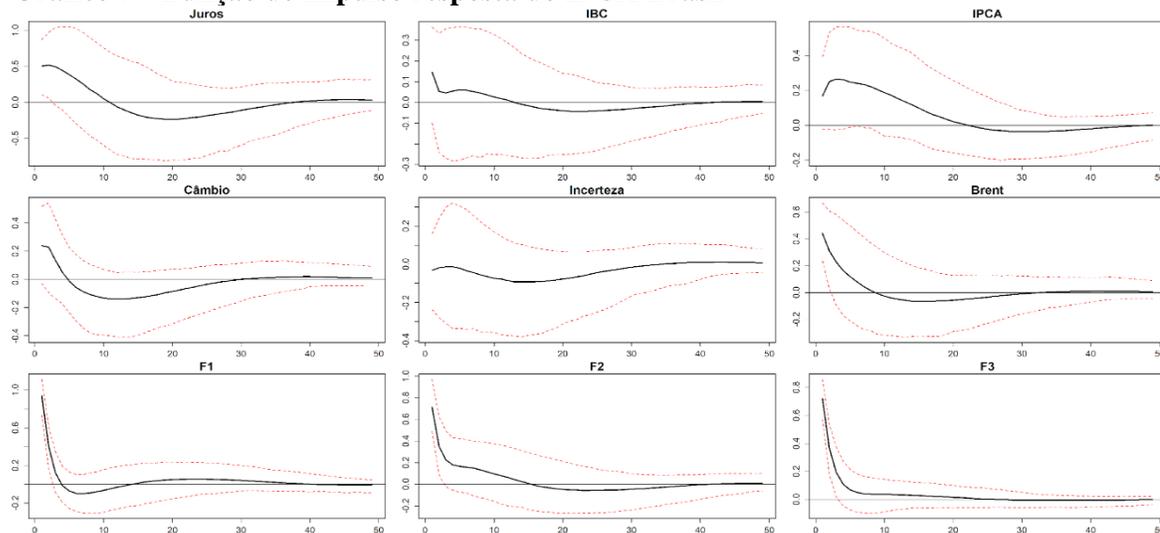
Os efeitos diretos surgem porque o índice geral de preços tem itens como alimentos e energia (*commodities*). Desta forma aumentos nos preços das *commodities* afetam diretamente o IPCA. Os efeitos indiretos surgem das expectativas de inflação que podem ser observadas nas respostas do núcleo de inflação. Em resumo, movimentos nos preços dos alimentos e energia (*commodities*) e das expectativas de inflação afetam a composição do IPCA, segundo Cheung (2009).

Importa mencionar que a dinâmica inflacionária se deve, em grande parte, a ela mesma e ao comportamento dos preços das *commodities* representado pelas variáveis F1, F2, F3 e o Petróleo Brent. Choques no índice de atividade econômica à resposta do IPCA é positiva nos primeiros períodos, voltando a sua trajetória inicial a partir do vigésimo período. Isso pode ser explicado pelo aumento das exportações das *commodities*, que impacta positivamente o saldo da balança comercial, acompanhando uma tendência crescente do índice de atividade econômica.

Por fim, a resposta da inflação a choques no índice de incerteza econômica pode se observar retração, voltando a sua trajetória original no vigésimo período. Há uma grande possibilidade da retração estar conectada a choques pontuais, por exemplo, a evolução dos preços das *commodities* pode estar relacionada pelo forte crescimento da demanda mundial por *commodities* e pela forte expansão comercial brasileira com os parceiros potenciais, China,

EUA, Japão, Alemanha, Holanda, Índia, Coreia do Sul, Espanha, dentre outros. Esses compradores e consumidores de *commodities*, especialmente agrícolas, são os principais impulsionadores do saldo positivo da balança comercial brasileira.

Gráfico 7 – Função de impulso resposta do IPCA-Brasil



Fonte: Elaboração própria.

No Gráfico 8 constam as respostas da taxa de juros aos choques de um desvio padrão nas variáveis: taxa de câmbio, inflação e preços de *commodities* agropecuárias F1 e F3. Observou-se retração na resposta da taxa de juros. Em todos os casos, após essa resposta inicial, há uma variação em torno da trajetória original até a estabilização no trigésimo período.

Estes resultados são coerentes com a teoria econômica. Uma vez que a taxa de juros é o principal instrumento de política monetária para controlar a inflação, as decisões de política monetária podem afetar os preços das *commodities*, conforme visto por Souza (2016). Elevadas taxas de juros reduzem a demanda por *commodities* armazenáveis, ou aumentam a oferta, através de uma variedade de canais, assim conduzindo a uma redução dos preços das *commodities* conforme apresenta a trajetória dos fatores F1 e F3.

Já o impacto de F2 na resposta da taxa de juros é positiva, inicialmente, com retração no quinto período, estabilizando-se no quadragésimo período. Altas taxas de juros causam movimentos cíclicos em F2 no curto prazo, visto que F2 está relacionado a *commodities* (pecuária bovina).

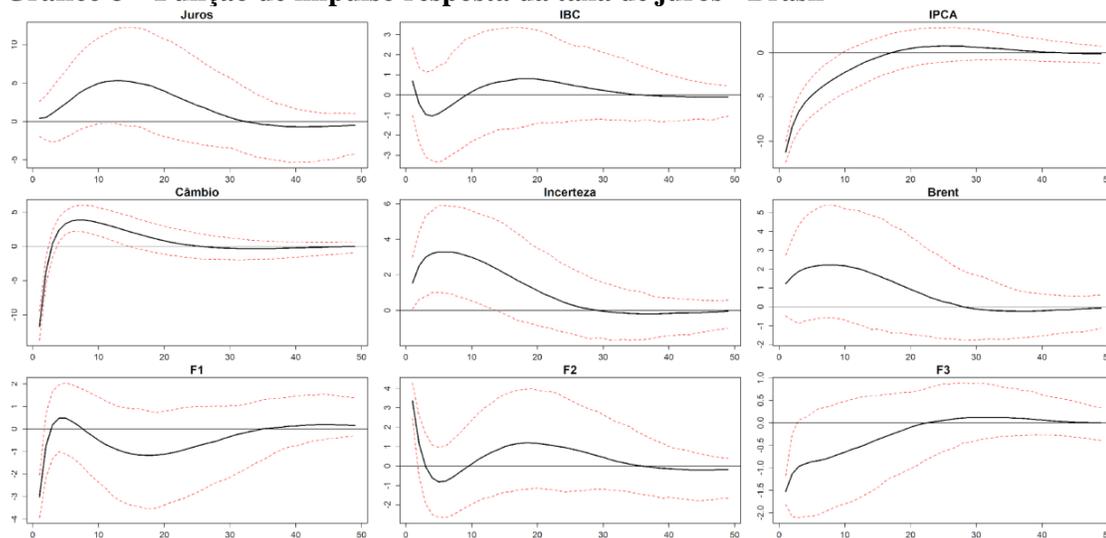
Havendo choques no índice de atividade econômica, a resposta da taxa de juros é positiva de início, com retração após o segundo período. Há uma variação em torno da trajetória original até a estabilização, evidenciando que o índice de atividade econômica é uma forma de

avaliar a evolução da atividade econômica brasileira, possibilitando as autoridades monetárias na administração da taxa de juros.

Explicando pelo lado do investimento, tem-se que altas taxas de juros desestimulam os investimentos e diminuem a demanda agregada. Já pelo lado das *commodities*, tem-se que a queda na taxa de juros provoca um aumento nos preços das *commodities*, uma vez que os investidores trocariam os títulos por *commodities* (consideradas como ativos financeiros). O índice de incerteza econômica e o preço do petróleo Brent exercem impacto positivo na taxa de juros, que se mantém persistente durante todo o período, evidenciando que variações no preço do petróleo causam distorções no índice de preço geral, que por sua vez, gera inflação e elevação da taxa de juros.

Conforme a teoria econômica, o investimento é o componente da demanda mais sensível em relação a taxa de juros, altas taxas de juros retrai a economia. importante mencionar que choques de incerteza são movimentos pontuais de elevação ou retração conforme apresenta o cenário econômico brasileiro.

Gráfico 8 – Função de impulso resposta da taxa de juros - Brasil



Fonte: Elaboração própria.

O Gráfico 9 mostra as respostas do petróleo Brent ao choque de um desvio padrão em relação à taxa de juros, à taxa de câmbio, à inflação e ao índice de atividade econômica. Há impactos positivos inicialmente, provocando desalinhamentos na trajetória do petróleo Brent durante todo o período; porém, de maneira positiva, com uma tendência ao retorno da trajetória após o trigésimo período.

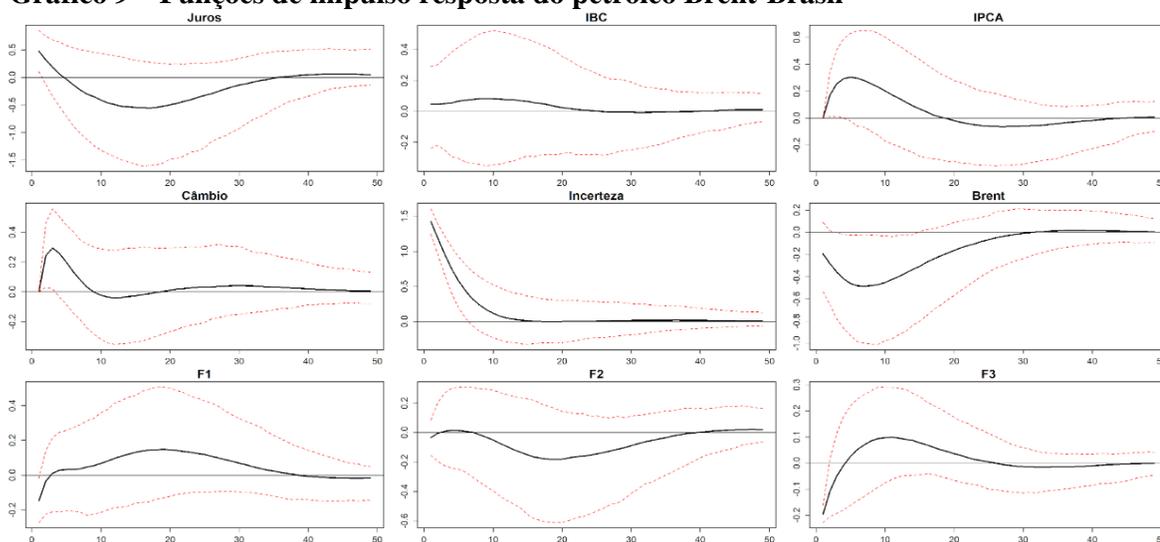
Estes resultados seguem alinhados com a literatura, uma vez que, o preço do combustível varia de acordo com o valor do barril de petróleo e, por ser uma *commodity*

negociada internacionalmente, com o valor do dólar. A forte pressão da demanda por petróleo, aumenta o custo do combustível, que por sua vez tem um peso bastante elevado para os negócios, especialmente no setor agrícola e na indústria. Por essa razão, reajustes no preço do petróleo trazem impactos diretos causando distorções na trajetória das variáveis taxa de juros, taxa de câmbio, inflação e índice de atividade econômica.

A resposta do petróleo Brent a choque nos fatores (F1, F2 e F3) relacionado a *commodities* agropecuárias. Há choque negativo no primeiro mês em cada um dos fatores. Após esse choque, segue uma tendência positiva ao retorno da trajetória, evidenciando que o petróleo é um importante condutor da variação nos preços agropecuários.

A resposta do petróleo a choques de um desvio padrão no índice de incerteza econômica é positiva durante todo o período. Esse resultado é esperado, uma vez que agropecuária e serviços (outros componentes do PIB) não sejam setores tão afetados pela incerteza quanto à indústria. Como o preço do petróleo impacta com mais intensidade os bens de investimento que são produzidos pelo setor industrial, e o investimento é um componente da demanda agregada, esta é mais sensível à incerteza (BLOOM, 2017). Posto isso, explica-se a relação direta do preço do petróleo com o índice de incerteza econômica brasileira, conforme mostra a trajetória. Por fim, choques no próprio petróleo Brent tem uma persistência negativa durante todo o período.

Gráfico 9 – Funções de impulso resposta do petróleo Brent-Brasil



Fonte: Elaboração própria.

Constam no Gráfico 10 as respostas do índice de atividade econômica aos choques das nove variáveis macroeconômicas. Há impactos positivos, e estatisticamente significativos,

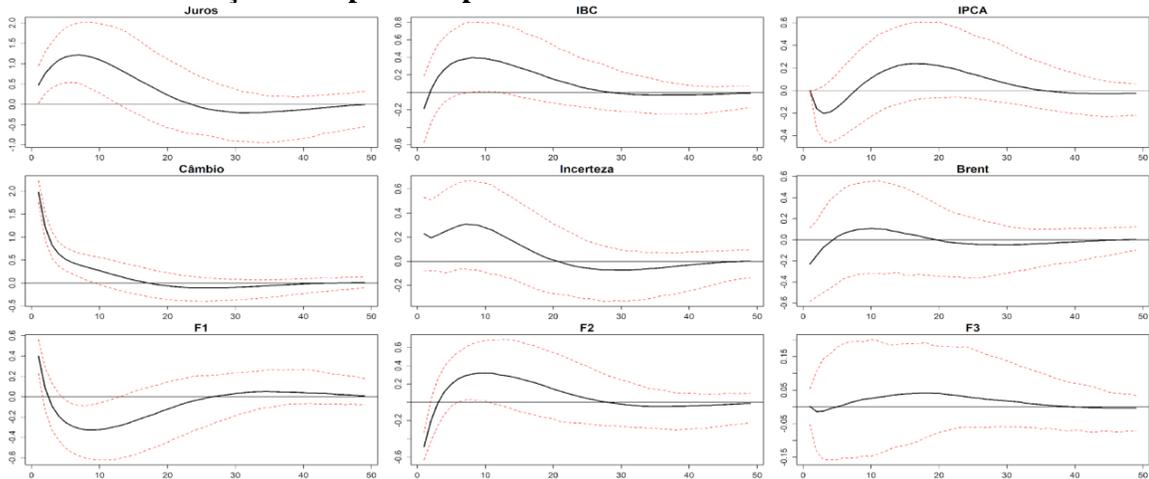
em cinco das novas medidas do índice de atividade econômica. Com relação ao impacto na taxa de juros, taxa de câmbio e F1, a resposta do índice de atividade econômica mostrou-se positiva por um curto período de tempo, em seguida contração e desalinhamento em toda trajetória. Esse resultado é esperado, visto que o índice de atividade econômica é mais sensível a essas variáveis.

Assim, já que o Brasil é pouco dependente de produtos importados, e um dos maiores exportadores de *commodities* agrícolas, o aumento das exportações poderá influenciar os preços desses produtos. Desta forma, as distorções nos termos de troca e o aumento do preço das *commodities* agropecuárias geram desalinhamentos na inflação. Como medida de controlar a inflação, o governo aumenta a taxa de juros, a qual encarece os empréstimos, portanto, desestimula os investimentos e retrai a economia, o que explica os movimentos dessas variáveis em relação ao índice de atividade econômica.

Choque no IPCA, no petróleo Brent e nos fatores F2 e F3 a resposta do índice de atividade econômica. Há contração no curto prazo, voltando à trajetória original no décimo período. Apresentando a importância dessas variáveis no comportamento do índice de atividade econômica.

Um aquecimento da atividade econômica aumenta a demanda por bens e serviços. Dada a influência das *commodities* na composição do IPCA, maiores preços das *commodities* agrícolas influenciam diretamente os preços dos alimentos e bebidas, uma vez que o consumo é um componente da demanda agregada, qualquer desequilíbrio na demanda agregada causa impacto no índice de atividade econômica, gerando incerteza no comportamento dos agentes econômicos.

Gráfico 10 – Função de impulso resposta do IBC-Brasil

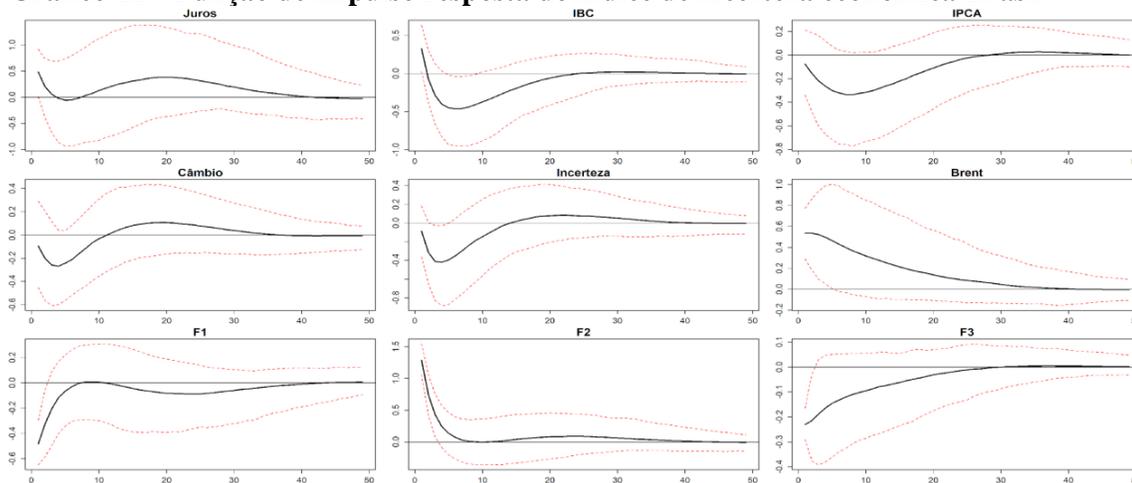


Fonte: Elaboração própria.

No Gráfico 11 estão as respostas do índice de incerteza econômica do Brasil a choques na: taxa de câmbio, na taxa de inflação e nos fatores F1 e F3 (*commodities* agropecuárias). Apresentam retração no primeiro período, e após o choque, desalinhamentos na trajetória durante todo o período. Esses resultados são esperados, visto que variações nos termos de troca, nos preços das *commodities* agropecuárias e inflação causam desequilíbrios no índice de incerteza econômica dada às expectativas dos agentes econômicos.

Observando os gráficos, percebe-se que o índice de incerteza econômica do Brasil responde positivamente a um choque na taxa de juros, no preço do petróleo Brent e no F2, relacionado a cana-de-açúcar, apresentando uma trajetória positiva durante todo o período. Esses resultados são esperados, na medida que variações tanto na taxa de juros como no preço do petróleo (combustíveis) causa variações no investimento. Uma vez que desequilíbrio nesses indicadores econômicos causam desequilíbrios no índice de incerteza econômica do país.

Gráfico 11 – Função de impulso resposta do índice de incerteza econômica-Brasil



Fonte: Elaboração própria.

3.5 Conclusão

As correlações dos grupos de preços de *commodities* agropecuárias mais representativas são as lavouras temporárias e a pecuária. O que pode ser explicado pelo aumento da demanda chinesa por esses produtos, tendo o Brasil como seu principal parceiro comercial. No contexto da produção de biocombustíveis, os preços das *commodities* (cana-de-açúcar, soja, mandioca e o milho) são alguns produtos que tiveram forte contribuições nos resultados das correlações dos fatores, ressaltando o milho como um dos produtos mais solicitados pelo mercado asiático, especialmente o chinês.

A taxa de câmbio responde positivamente a choques no índice de incerteza econômica e a inflação, indicando a importância das exportações brasileiras, especialmente de *commodities* agropecuárias. À medida que aumenta a receita de exportação, aumenta o valor das exportações, apreciando a taxa de câmbio, visto que esse movimento causa uma redução no volume exportado. Caso o efeito líquido seja positivo, haverá um aumento da renda nacional e da demanda agregada que, conseqüentemente, aumenta a produção, o emprego e o nível de preços.

A resposta da inflação aos choques da taxa de juros, índice de atividade econômica, taxa de câmbio, petróleo Brent, preços agropecuários representados pelos fatores F1, F2 e F3 e a própria inflação tem impactos positivos e estatisticamente significativos. Importa mencionar que a dinâmica inflacionária se deve em grande parte a ela mesma e ao comportamento dos preços das *commodities* representadas pelas variáveis F1, F2, F3 e o Petróleo Brent.

A resposta da taxa de juros aos choques da taxa de câmbio, inflação e os preços agropecuários F1 e F3 têm impactos positivos e estatisticamente significativos. Estes resultados são coerentes com a teoria econômica. Uma vez que a taxa de juros é o principal instrumento de política monetária para controlar a inflação; as decisões de política monetária podem afetar os preços agropecuários.

A resposta do preço do petróleo Brent aos choques nos fatores F1, F2 e F3 relacionado aos preços agropecuários. Há impactos negativos no primeiro mês em cada um dos fatores, após esse choque, segue uma tendência positiva retornando à trajetória, evidenciando que o preço do petróleo Brent é um importante condutor na variação dos preços agropecuários, devido o preço do petróleo Brent ser negociado no mercado internacional, as variações deste produto causam variações nos preços agropecuários. Este achado corrobora o que já havia encontrado Nazlioglu e Soytaş (2011).

A resposta do índice de atividade econômica aos choques da taxa de juros, da taxa de câmbio, nos fatores F1 e F3. Há impactos positivos e estatisticamente significativos. Esse resultado é esperado, visto que o índice de atividade econômica é mais sensível a essas variáveis, uma vez que o Brasil é pouco dependente de produtos importados e um dos maiores exportadores de *commodities* agropecuárias, com os aumentos do volume exportado destes itens melhoram a balança comercial, e por sua vez, melhoram o índice de atividade econômica.

Em relação à resposta do índice de incerteza econômica aos choques da taxa de câmbio, inflação e dos fatores F1 e F3 relacionados aos preços agropecuários, ocorre uma retração no primeiro período, e após o choque, desalinhamentos na trajetória durante todo o período. Esses resultados são esperados, visto que variações nos termos de troca, nos preços

agropecuários e inflação causam desequilíbrio no índice de incerteza econômica dada às expectativas dos agentes econômicos.

As evidências encontradas neste estudo mostram que o aumento das exportações brasileiras pode ser decorrente do aumento da demanda chinesa pelos produtos agropecuários brasileiros, causando impacto diretamente no aumento dos preços desses produtos. Dessa forma, as autoridades monetárias ao tomar decisões a respeito da determinação da taxa de juros devem levar em consideração o índice de preços das *commodities* agropecuárias e suas influências sobre a taxa de câmbio real.

4 NÚCLEO DA INFLAÇÃO: UMA APLICAÇÃO DO MODELO DE COMPONENTES NÃO OBSERVADOS PARA O BRASIL

O crescimento sustentável de um país é meta de qualquer governo. Porém, um dos gatilhos desencadeadores para um crescimento sustentável está atribuído a importância da meta de estabilidade de preços. É importante entender que o aumento de preço de algum bem ou serviço em particular não constitui inflação, o que ocorre quando há um aumento generalizado dos preços. Normalmente, esses aumentos de preços não ocorrem de forma sincronizada, desse modo, manter estáveis esses aumentos de preços em uma economia, são primordiais.

Historicamente o Brasil vivenciou longos períodos de hiperinflação na década de 1990, quando o índice de inflação chegou a atingir 80% mensal (GREMAUD *et al.*, 2014). O cenário problemático de incerteza econômica fez com que os brasileiros experienciassem total desequilíbrio econômico e falta de perspectiva de uma melhora na qualidade de vida. Por causas circunstanciais monitorar o núcleo de inflação é necessário para a definição de metas para a inflação no país.

Em julho de 1999 o sistema de metas de inflação foi implementado tendo como referência o Índice de Preços ao Consumidor Amplo (IPCA)²⁰ determinado como índice de inflação para a meta, com um sistema de bandas. Dessa forma, o Comitê de Política Monetária (Copom) deve procurar conduzir a política monetária de modo que suas projeções de inflação apontem inflação convergindo para a meta (BACEN, 2018).

Em linhas gerais, o núcleo e o sistema de metas possuem funções diferentes. O núcleo indica a tendência de comportamento da inflação, enquanto as metas indicam para onde se deseja conduzir a inflação. Seguindo esse critério, o Banco Central do Brasil (BCB) utiliza como principal instrumento de política monetária para o controle do IPCA, a fixação da taxa de juros SELIC realizada pelo Copom, sendo que os núcleos do IPCA são medidas importantes para a tomada de decisão do Copom.

4.1 Introdução

O núcleo de inflação em sua essência, deve cumprir três funções: separar choques de preços idiossincráticos de choques generalizados; separar choques temporários de choques persistentes; e antecipar a tendência de curto prazo da inflação (BACEN, 2018)). Assim,

²⁰ IPCA- calculado pelo IBGE (Instituto Brasileiro de Geografia e Estatística), justificado por ser o índice de preços de maior abrangência existente no país, que mede a inflação para domicílios com renda entre 1 a 40 salários-mínimos em 13 cidades ou regiões metropolitanas.

administrar essas funções são medidas fundamentais no exercício de decisões de política monetária com o intuito de não incorrer em fortes desvios da inflação em relação a uma meta previamente estabelecida.

A crescente importância atribuída à meta de estabilidade de preços e à introdução de modelagens explícitas de inflação tem estimulado muitos estudos com a intenção de construir medidas mais consistentes de inflação e, em particular, de indicadores de núcleo da inflação. O presente ensaio tem como objetivo a construção de uma medida de núcleo para o índice de inflação IPCA utilizando como metodologia um modelo multivariado de componentes não observados seguindo Harvey e Koopman (2009). O modelo é composto pelas variáveis macroeconômicas PIB real, taxa de juros SELIC nominal, oferta do agregado monetário M1 em termos reais e a taxa de inflação IPCA seguindo os trabalhos de Bagliano *et al.*, (2002) e Goldfeld (1990).

O núcleo gerado pelo modelo de componentes não observados (IPCA_CN) corresponde a tendência estocástica estimada para o IPCA. Em seguida é verificado se o núcleo produzido atende às condições para uma medida de núcleo, segundo Marques *et al.*, (2003), e se ele possui boa capacidade de previsão fora da amostra. Tanto os testes das condições como a análise da capacidade preditiva são realizados em comparação com três outros núcleos produzidos pelo BC, o núcleo por exclusão sem monitorados e alimentos no domicílio (IPCA_EX), o núcleo de dupla ponderação (IPCA_DP) e o núcleo de médias aparadas com suavização (IPCA_MS).

4.2 Revisão da literatura

São várias as abordagens para medir o núcleo da inflação na literatura, uma delas chama-se medida de influência limitada²¹. Esta abordagem corresponde a medidas de corte transversal do núcleo da inflação, que são obtidas a partir da aplicação de técnicas estatísticas sobre os dados da distribuição dos preços em cada período. Dentro desta abordagem estão: as medidas de Médias Aparadas²² (MA) e Mediana Ponderada²³ (MP). O uso de média aparada e

²¹ Esta é uma abordagem alternativa para medidas convencionais de inflação (excluir alimentos e energia), ou seja, excluir uma porcentagem de cada parte da distribuição de corte transversal das variações de preços e considera a média ponderada das variações de preços para o restante dos componentes no índice de preços agregados. Essas medidas se baseiam na definição de núcleo como inflação generalizada e procuram eliminar as variações extremas de preço como uma forma de estimar o componente comum.

²² Médias aparadas excluem do cálculo do índice de preços os itens que apresentam variações extremas, isto é, as maiores e menores variações em um dado período.

²³ Nesse caso, em vez de ignorar os extremos das distribuições dos pesos, considera-se apenas o peso central ou o imediatamente superior.

mediana como medida central de inflação pode ser justificado com base em sua eficiência quando a distribuição estatística das variações de preços é simétrica, embora leptocúrtica²⁴.

Outras medidas para extrair o núcleo da inflação foram adotadas. Com base na abordagem Smith (2004), que usa os modelos de previsão condicional e incondicional, o autor afirma que o Índice de Preço do Consumidor Média Ponderada (IPC-MP) supera o Índice de Preço do Consumidor principal (IPC-P).

Meyer *et.al.*, (2010) mostram que o (IPC-MA) e o (IPC-MP) de 16% projetam a previsão para o ano seguinte. Já Crone *et al.*, (2013) descobriram que em horizontes mais longos (ou seja, 24 meses), o IPC-MA produz uma previsão significativamente superior em relação ao IPC (ex alimentos e energia). Meyer e Venkatu (2014) revelam que as medidas de (MA) explicam as variações mensais mais voláteis dos preços com ruídos e as limitam da distribuição de variações de preços, deixando um sinal de informação mais claro para trás, em relação IPCA (ex alimentos e energia).

No entanto, estudos como o de Meyer e Zaman (2019), para os EUA; da Silva Filho e Figueiredo (2014) e Santos e Castelar (2016), para o Brasil, identificaram os principais problemas das medidas de (MA). Eles mostram que as medidas de (MA) não fazem distinção entre distúrbios persistentes e transitórios. Esse comportamento transitório, por conseguinte, adiciona ruído ao índice da inflação, e não reflete o aumento persistente no nível dos preços.

No Brasil as medidas de núcleos²⁵ que são acompanhadas pelo Banco Central, este em um estudo recente realizado entre os períodos de 2011-2017 realizou uma análise da evolução de algumas medidas de núcleos tais como: Índice de Preço do Consumidor com Exclusão (IPCA-EX), Índice de Preço do Consumidor com Média Aparada (IPCA-MA), Índice de Preço do Consumidor Média Aparada com Suavização (IPCA-MS) e Índice de Preço do Consumidor com Dupla Ponderação (IPCA-DP).

Esse estudo apresenta que em termos de volatilidade, o (IPCA-MS) e (IPCA-MA) são os núcleos com menor desvio padrão no período entre 2006/2017, mas todos os núcleos

²⁴ Essa distribuição possui caudas pesadas, ou seja, a função de distribuição é mais achatada do que a distribuição normal conforme visto por (SHARMA; BICCHAL 2015).

²⁵ O núcleo IPCA-EX0 é obtido pela exclusão de Alimentação no Domicílio e Monitorados. O IPCA-EX1 exclui 10 dos 16 itens do subgrupo alimentação no domicílio, além dos itens combustíveis domésticos e combustíveis de veículos. O núcleo por médias aparadas (IPCA-MA) exclui os itens cuja variação mensal se situe, na distribuição, acima de 80 ou abaixo de 20 percentis. O núcleo de médias aparadas com suavização (IPCA-MS) segue o mesmo procedimento da medida anterior, com a diferença de que, antes da eliminação das caudas, são suavizados os componentes com variações infrequentes. O núcleo de dupla ponderação (IPCA-DP) ajusta os pesos originais de cada item de acordo com sua volatilidade relativa, procedimento que reduz a importância de componentes mais voláteis.

apresentam volatilidade significativamente menor do que o (IPCA) cheio. Os (IPCA-DP), (IPCA-MA) e (IPCA-MS) apresentam as melhores estatísticas, seguidos do (IPCA-EX1).

São várias as abordagens para eliminar os movimentos transitórios dos preços, portanto, o grau em que uma medida do núcleo captura com êxito a taxa de inflação subjacente da tendência é geralmente avaliado pela capacidade de prever a inflação global em um horizonte de tempo. No entanto, se uma medida de núcleo de inflação obter informações úteis para prever a taxa global de inflação em data futura, então quando houver uma diferença entre a inflação global e a inflação global no período atual, a inflação global, em parte, voltará ao núcleo (GAMBER, *et al.*, 2015). Assim, são vários os critérios para avaliar a construção de núcleo de inflação, mas nenhum na literatura é específico.

4.2.1 Modelagens de núcleos

González *et al.*, (2011), para estimar o núcleo da inflação turca, utilizam o modelo Autorregressivos de Médias Móveis (ARMA). Nesse método, o núcleo de inflação é medido como uma série de mudanças no nível médio de inflação. O método (ARMA) é completamente paramétrico, no sentido de permitir a mudança de modelagem média e qualquer estrutura dinâmica ao seu redor simultaneamente, pois é semelhante ao método de suavização exponencial (ES).

Harvey (2011) estuda a relação entre inflação e PIB americano, através da modelagem de uma curva de Phillips com componentes não observados. Os dados foram trimestrais de janeiro de 1947 a fevereiro de 2007. Os resultados revelam que modelos de equação única e bivariados são semelhantes e que o hiato do produto 2% acima da tendência está associada a uma taxa de inflação anual 1% acima do núcleo da inflação e que a inflação central tem sido estável, dentro de uma faixa de 3%.

A fim de preverem a inflação turca, Oğünç *et al.*, (2013) realizam uma avaliação do desempenho de várias técnicas de modelagem como: modelos de fatores univariados, modelos de curva Phillips que variam no tempo, modelos baseados em decomposição, modelos (VAR) e VAR- Bayesiano. Para os modelos de fatores, os autores usam um modelo de equação única com fatores e um modelo VAR Aumentados com os Fatores (Favar).

Os resultados mostram que os modelos de fatores apresentam desempenho ruim. Em relação ao modelo de equação única, o modelo fatorial supera a referência passeio aleatório apenas para as previsões de dois quartos à frente. O Favar supera o passeio aleatório pelo horizonte de um a três quartos à frente, embora esse modelo seja relativamente bem-sucedido

nas previsões de dois quartos à frente, para as previsões de um e três quartos à frente, existem modelos mais bem-sucedidos.

Bacio (2015) estuda as principais medidas de inflação na Romênia, por meio do teste de causalidade de Granger, com base em dados mensais entre agosto de 2005 a setembro 2014 utilizando as principais medidas de inflação e a inflação quantificada pelo (IPC). Os resultados mostram que o núcleo pode ser usado como uma prevenção para a inflação geral, apenas para o curto prazo. Após agosto de 2005, o Bacen da Romênia conseguiu controlar o fenômeno inflacionário por meio de uma mistura de políticas macroeconomia, para um nível mínimo histórico de 0,41% em janeiro de 2015.

Amparado na modelagem de González *et al.*, (2011), Kulaksizoglu (2016) compara os métodos (ARMA) e (ES) usando o (IPC-EX) Turco mensal de 1955 a 2015 e descobriu que, em termos de acompanhamento da tendência de inflação o (ARMA), é mais adequado, pois ajuda a detectar as datas exatas das mudanças entre diferentes regimes de inflação e a duração de cada regime. Reigl (2017) apresenta previsões de inflação global e principal na Estônia com modelos de fatores em uma estrutura pseudo-fora-de-amostra recursiva. Os fatores são construídos com uma análise de componentes principais e, em seguida, incorporados aos modelos de previsão (VAR). O autor revela que certos modelos de (VAR) aumentados por fator aprimoram um modelo autorregressivo univariado simples, mas os ganhos de previsão são pequenos e não sistemáticos.

Silva *et al.*, (2017) apresentam uma nova modelagem para analisar a (IPCA) e o PIB brasileiro com base nos modelos (VAR) com Variáveis Exógenas (VARX) e (VAR) entre os períodos de 1995 – 2015. Os resultados mostram que para os modelos (VARX) a relação entre o deflator do PIB e o (IPCA) fica acima de um, em um cenário neutro e otimista, menor que um para um cenário pessimista. O autor afirma que os modelos mostram que quanto mais valorizado o real e quanto maior a utilização da capacidade instalada, maior a relação entre o deflator do PIB e o (IPCA).

Acosta (2018) propõe a metodologia nos termos de Blinder (1997)²⁶ para a construção de medidas básicas de inflação usando algoritmo de aprendizado de máquina de agrupamento k-means. O autor utiliza o IPC mexicano, com o objetivo de obter um sinal claro e ter boas previsões do processo inflacionário, com base na seleção de itens com baixa volatilidade e na atribuição a clusters. Os resultados mostram que o núcleo de inflação

²⁶ Essa metodologia tem finalidade de obter um sinal claro para obter boas previsões do processo inflacionário, com base na seleção de itens com baixa volatilidade e na atribuição a clusters. Para mais informações ver o estudo de Blinder (1997).

construído capta melhor o sinal de inflação e supera as previsões de inflação de curto prazo obtidas pelo método das médias aparadas e o núcleo de inflação, excluindo alimentos e energia.

Phiri (2018) adota a metodologia de Regressão Automática Quantil (QAR) a fim de investigar a persistência da inflação nos países BRICS usando dados trimestrais entre 1996 e 2016. Concluem dois momentos, primeiro para todas as regressões estimadas, a persistência da inflação nos percentis mais altos da regressão QAR exhibe tendências de raiz unitária. Segundo, observou-se que a crise financeira global alterou os níveis de persistência da inflação em todos os quantis para todos os países do BRICS. Portanto, os resultados sugerem que as autoridades monetárias nos países dos BRICS devem manter a taxas de inflação baixa e estáveis.

Kose *et al.*, (2018) avaliam os efeitos da meta de inflação em relação: ao crescimento do produto, taxas de câmbio real, volatilidade da inflação e volatilidade da taxa de câmbio real, com base em 16 países que adotam meta de inflação e 21 sem metas, usando a técnica de Diferença na Diferença (DID). Os períodos de análises são de 1996 a 1999 e 2007 a 2015 para os grupos sem metas e com meta de inflação. Os resultados mostram que a meta de inflação foi superior em termos de aproveitamento da inflação e de sua volatilidade, em termos de crescimento econômico a meta de inflação parece ser neutra e, em termos de taxas de câmbio real apresenta não estabilizada. Para os grupos sem metas de inflação os períodos de análise são de 1996 a 1999 e 2007 a 2015 para os grupos com meta de inflação.

Meyer e Zaman (2019) estão interessados em saber se o uso do (IPC) mediano como medida de inflação subjacente no modelo Vetores Autorregressivo Bayesianos (BVARs) possuem algumas diferenças consideráveis na precisão das previsões (PIB real, inflação, taxa de fundos federais e taxa de desemprego).

Os resultados sugerem que o (IPC) mediano é uma medida mais precisa da inflação subjacente, já em relação ao (IPC-EX) núcleo este apresenta uma adição útil de variedade de BVARs usados para previsão, especialmente na estabilização da política monetária.

4.3 Metodologia

Nesta seção consta a explanação de alguns modelos que serão úteis à análise visada.

4.3.1 Modelo de componentes não observados

Segundo Lenten e Rulli (2006), os dados das séries temporais são compostos por componentes não observáveis como tendência, ciclo, sazonalidade e componente irregular, cada um dos quais podem ser modelados separadamente. Dessa forma, a modelagem de

componentes não observáveis permite capturar propriedades que são complexas e dinâmicas, entendendo melhor a natureza desses componentes que determinam o comportamento das séries temporais.

4.3.2 Modelo linear univariado

Seja a distribuição normal y_t um modelo de nível local em que consiste em um componente passeio aleatório μ_t mais um termo irregular, isto é,

$$\mu_t = \mu_{t-1} + \eta_t \quad \eta_t \sim NID(0, \sigma_\eta^2) \quad t = 1, \dots, T \quad (17)$$

$$y_t = \mu_t + E_t \quad \eta_t \sim NID(0, \sigma_\varepsilon^2) \quad (18)$$

Os distúrbios E_t e η_t são mutuamente independentes e $NID(0, \sigma^2)$ que denota um processo de ruído branco normalmente distribuído com média zero e variância δ^2 . Assim quando σ_η^2 é zero, o componente de passeio aleatório μ_t torna-se constante. O sinal-relação representado por um ruído $q = \sigma_\varepsilon^2 / \sigma_\eta^2$ desempenha um papel fundamental na ponderação das observações para previsão e extração de sinal. Especificamente, no estado estacionário, as previsões do filtro Kalman são implicitamente formadas como uma ponderação média móvel exponencial de observações anteriores, logo,

$$\tilde{y}_{T+1|T} = \lambda \sum_{j=0}^{\infty} (1 - \lambda)^j y_{T-j} \quad (19)$$

Os pesos das observações anteriores são determinados por λ , e este parâmetro está diretamente relacionado à relação sinal-ruído pela fórmula $\lambda = (-q + \sqrt{q^2 + 4q}) / 2$. Observe que um valor mais alto de q implica um desconto mais rápido das observações anteriores em (18).

O modelo de tendência linear local generaliza o nível local introduzindo em (19) uma inclinação estocástica β_t , que por sua vez segue um passeio aleatório. Dessa forma desenvolvemos (18) da seguinte maneira,

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t \quad \eta_t \sim NID(0, \sigma_\eta^2) \quad (20)$$

$$\beta_t = \beta_{t-1} + \zeta_t \quad \zeta_t \sim NID(0, \sigma_\zeta^2) \quad (21)$$

Os distúrbios ε_t , η_t e ζ_t são mutuamente independentes. Se as variações σ_η^2 e σ_ζ^2 ambos são zero, então a tendência é determinista. Se apenas σ_ζ^2 for igual à zero, a inclinação será fixa, e a tendência se reduz a um passeio aleatório com drift. Permitir que σ_ζ^2 seja positivo, mas definir σ_η^2 como zero, dá uma *tendência de passeio aleatório integrado*, que quando estimado pela extração de sinal, tende a evoluir lentamente ao longo do tempo.

A tendência estocástica pode ser combinada com um ciclo estocástico ψ_t para fornecer o modelo de decomposição do ciclo de tendência, ou seja,

$$y_t = \mu_t + \psi_t + \varepsilon_t, \quad t = 1, \dots, T \quad (22)$$

A componente cíclica na formulação estrutural é modelada na seguinte forma equivalente:

$$\begin{aligned} [\psi_t \ \psi_t^*] &= \rho [\cos \cos \lambda_c \ \sin \sin \lambda_c \ \sin \sin \lambda_c \ \cos \cos \lambda_c] [\psi_{t-1} \ \psi_{t-1}^*] + \\ &[K_t \ K_t^*], \quad t = 1, \dots, T, \end{aligned} \quad (23)$$

λ_c é um parâmetro no intervalo $0 \leq \lambda_c \leq \pi$, ρ é um fator de amortecimento, e K_t e K_t^* são gaussianos mutuamente independentes distúrbios de ruído branco com média zero e variância constante σ_k^2 .

Supondo que o vetor inicial $(\psi_0, \psi_0^*)'$ possua média zero e matriz de covariância $\sigma_\psi^2 I_2$ e que $\rho \leq 1$, logo ψ_t é estacionário. Portanto o aspecto do ciclo estocástico (22) exhibe um pico que se torna mais nítido à medida que ρ se aproxima de um. Quando o caso for especial tem-se $\sigma_k^2 = 0$ e o ciclo é determinístico.

4.3.3 Modelos lineares multivariados

Assumindo que as observações nas séries temporais N estejam disponíveis, o modelo de tendência linear local pode ser generalizado para se tornar da seguinte forma,

$$y_t = \mu_t + \varepsilon_t \quad \varepsilon_t \sim NID(0, \Sigma_\varepsilon), \quad t = 1, \dots, T \quad (24)$$

Em que $y_t = (y_{1t}, \dots, y_{Nt})'$ e distúrbio ε_t é o $N \times 1$ irregular vetor. O $N \times 1$ vetor de tendência μ_t depende do $N \times 1$ vetores de perturbação η_t e ζ_t . A especificação dinâmica para o componente de tendência μ_t é dado por

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t \quad \eta_t \sim NID(0, \Sigma_\eta) \quad (25)$$

$$\beta_t = \beta_{t-1} + \zeta_t \quad \zeta_t \sim NID(0, \Sigma_\zeta) \quad (26)$$

β_t é o vetor $N \times 1$ de inclinações. As correlações implícitas pelas matrizes de covariância Σ_η e Σ_ζ capturam as relações entre o permanente, isto é, subjacente, partes da série, enquanto as correlações em Σ_ε refletem transitórias, isto é, associações de curto prazo.

O modelo (24) pode ser generalizado para se tornar um processo vetorial autorregressivo estacionário para captura das interações entre as séries de curto prazo. Outra possibilidade é adicionar um ciclo multivariado ψ_t especificado da seguinte forma,

$$\begin{aligned} [\psi_t \ \psi_t^*] &= [\rho(\cos \cos \lambda_c \ \sin \sin \lambda_c \ \sin \sin \lambda_c \ \cos \cos \lambda_c)] \otimes I_N [\psi_{t-1} \ \psi_{t-1}^*] + \\ &[\kappa_t \ \kappa_t^*], \end{aligned} \quad (27)$$

K_t e K_t^* são $N \times 1$ vetores de distúrbios gaussianos de modo que $E(K_t K_t') = E(K_t^* K_t^{*'}) = \Sigma_k$, $E(K_t K_t^*) = 0$, e Σ_k é uma Matriz de covariâncias $N \times N$. O operador \otimes na equação (11) denota o produto da matriz de Kronecker. Uma vez que os parâmetros ρ e λ_c são os mesmos em todas as N séries temporais, os ciclos têm os mesmos aspectos e, portanto, são chamados de ciclos semelhantes.

Aplica-se o modelo de componentes não observados multivariado acima utilizando as variáveis mensais PIB real, taxa de juros SELIC nominal, oferta do agregado monetário M1 em termos reais e a taxa de inflação IPCA com variação do acumulado em 12 meses. O componente de tendência estocástica *referente ao IPCA contida no vetor μ_t* apresentada na equação (25), é o núcleo de inflação para o IPCA, definido como IPCA_CN. Esse núcleo estimado tem a característica de captar o comportamento permanente do IPCA, conter informações da atividade econômica retratada pelo PIB e dos dois principais mecanismos de política monetária para o controle da meta inflacionária: os controles da Selic e da oferta monetária M1.

4.3.4 O filtro de Kalman

O filtro de Kalman é um recurso básico para estimar os componentes não observados, em um modelo linear de espaço de estados. As estimativas, que são baseadas em observações atuais e passadas, podem ser usadas para fazer previsões. As recursões para trás produzem estimativas suavizadas de componentes em cada ponto no tempo com base em observações passadas, atuais e futuras.

Um conjunto de erros de previsão um passo à frente, chamados de inovações, é produzido pelo filtro de Kalman. Em um modelo gaussiano, as inovações podem ser usadas para construir uma função de verossimilhança que pode ser maximizada numericamente em relação a parâmetros desconhecidos no sistema conforme apresenta Schweppe (1965). Uma vez que os parâmetros são estimados, as inovações podem ser usadas para construir estatísticas de teste que são projetadas para avaliar quão bem o modelo se ajusta.

O filtro de Kalman é um algoritmo recursivo que calcula a estimativa quadrada média mínima (MMSE) do vetor estado baseado nas informações do passado. No modelo de nível local como apresentados nas equações (17) e (18), o filtro de Kalman avalia o MMSE do nível, $\tilde{\mu}_{t|t-1} = E(\mu_t | y_t, \dots, y_{t-1})$ junto com seu erro quadrático médio, para $t = 2, \dots, T$. A função de verossimilhança do modelo pode ser obtida a partir dos erros de previsão $v_t = y_t - \tilde{\mu}_{t|t-1}$ para $t = 2, \dots, T$. O algoritmo pode ainda lidar com condições iniciais desconhecidas,

efeitos fixos de regressão, valores ausentes e previsões. Algoritmos de suavização relacionados foram desenvolvidos para avaliar MMSEs de μ_t com base em todas as observações $y_1 \dots, y_T$. Quando a suposição gaussiana não é válida, os métodos produzem estimadores lineares mínimos quadrados médios. Detalhamento sobre o filtro de Kalman e métodos relacionados são apresentados em Durbin e Koopman (2001) e Harvey (1989).

4.3.5 Condições para uma medida de núcleo de inflação

Seguindo Marques *et al.*, (2003), analisa-se nesta seção um conjunto de condições estatísticas que devem ser atendidas em indicadores de núcleo de inflação. Assume-se que para qualquer período de tempo t , a taxa de inflação (π_t) pode ser decomposta em um componente permanente, denominado núcleo ou tendência da inflação (π_t^*), e um componente transitório (u_t). Por definição, em cada período de tempo, tem-se:

$$\pi_t = \pi_t^* + u_t \quad (28)$$

Na equação (28) assume-se que u_t corresponde aos distúrbios transitórios na taxa de inflação. Por definição u_t tem média zero e variância finita, sendo, portanto, uma série estacionária fraca. Quando a taxa de inflação, π_t , é $I(1)$, diz-se que π_t^* é uma medida de núcleo de inflação se:

(i) π_t^* é $I(1)$ e π_t e π_t^* são cointegradas com coeficiente unitário, isto é $\pi_t - \pi_t^*$ é uma série estacionária com média zero;

(ii) Existe um mecanismo de correção de erro dado por $Z_{t-1} = (\pi_{t-1} - \pi_{t-1}^*)$ para $\Delta\pi_t$, isto é $\Delta\pi_t$ pode ser escrito como:

$$\Delta\pi_t = \sum_{j=1}^m \alpha_j \Delta\pi_{t-j} + \sum_{j=1}^n \beta_j \Delta\pi_{t-j}^* - \gamma(\pi_{t-1} - \pi_{t-1}^*) + \varepsilon_t \quad (29)$$

(iii) π_t^* é fortemente exógeno para os parâmetros da equação (29).

A condição (i) implica que a taxa de inflação e a medida de núcleo devem exibir uma tendência comum; caso contrário, o núcleo poderá fornecer uma sinalização errada do comportamento futuro da taxa de inflação. Do Teorema da Representação de Granger, sabe-se que se a condição (i) se mantém, então existe uma representação de correção de erro pelo menos para uma das variáveis π_t ou π_t^* . A condição (ii) requer que esta representação exista especificamente para π_t ; isto é, que o termo Z_{t-1} apareça na equação $\Delta\pi_t$. Nesse caso, π_t^* deve se comportar como um atrator para π_t no sentido que, no longo prazo, π_t deva convergir para π_t^* . Note-se que a condição (ii) é um caso especial de causalidade de Granger a qual requer que π_t^* cause π_t no sentido de Granger. Com efeito, π_t^* é também um indicador antecedente de π_t .

A condição (iii) indica que π_t não deve ser um atrator para π_t^* e também que π_t^* não seja sensível a outliers observados em π_t . Esta condição implica simultaneamente que o termo de correção de erro não apareça na equação para π_t^* (isto é que π_t^* seja fracamente exógena para os parâmetros do vetor cointegrante) e também que π_t não cause π_t^* no sentido de Granger. Em outras palavras, a condição (iii) implica que no modelo de correção de erro para π_t^* é,

$$\Delta\pi_t^* = \sum_{j=1}^r \delta_j \Delta\pi_{t-j}^* + \sum_{j=1}^s \theta_j \Delta\pi_{t-j} - \lambda(\pi_{t-1}^* - \pi_{t-1}) + \eta_t \quad (30)$$

deve-se ter $\lambda = \theta_1 = \dots = \theta_s = 0$.

O teste da condição (i) pode ser conduzido de diferentes formas, como testar a hipótese $(\alpha, \beta) = (0, 1)$ na regressão $\pi_t = \alpha + \beta\pi_t^* + v_t$, utilizar um teste de cointegração; ou ainda através de um teste de raiz unitária verificar se a série $Z_t = (\pi_t - \pi_t^*)$ é estacionária. A condição (i) pode ser testada em duas etapas. Primeiro usa-se o teste de raiz unitária ADF para estabelecer a estacionariedade de $Z_t = (\pi_t - \pi_t^*)$. Depois testa-se a não rejeição da hipótese nula $\alpha = 0$ na regressão $\pi_t = \alpha + \beta\pi_t^* + v_t$, dado que a série Z_t é estacionária. Note-se que considerando a regressão cointegrante:

$$(\pi_t - \pi_t^*) = \alpha + (\beta - 1)\pi_t^* + u_t \quad (31)$$

Conclui-se que $(\pi_t - \pi_t^*)$ é estacionária se, e somente se, u_t é estacionária²⁷ e $\beta = 1$.

Dado que a condição (i) seja satisfeita, o teste para a condição (ii) é conduzido estimando a equação (30) e testando a rejeição da hipótese nula $\gamma = 0$, utilizando o teste t convencional. Também neste caso um teste de cointegração pode ser utilizado. Para testar a condição (iii) estima-se a equação (31) e testa-se a hipótese nula $\lambda = \theta_1 = \dots = \theta_s = 0$. O teste para esta condição é conduzido em duas etapas. Primeiro simplesmente testa-se a hipótese nula $\lambda = 0$ (exogeneidade fraca). Depois, dado que não se rejeita a hipótese nula, testa-se a hipótese $\theta_1 = \dots = \theta_s = 0$ (exogeneidade forte).

A estratégia utilizada na presente seção para verificar as condições para uma medida de núcleo de inflação, segundo Marques *et al.*, (2003), dado que tanto o IPCA quanto os núcleos são integrados de ordem 1, $I(1)$, será executada seguindo os seguintes passos:

1. Aplica-se os testes de cointegração Engle e Granger (1987) e Phillips e Ouliaris (1990), baseados na estacionariedade dos resíduos das regressões bivariadas entre duas variáveis $I(1)$, no caso o IPCA e o seu núcleo;

2. Dada a existência de cointegração entre o IPCA e o seu núcleo, aplica-se o Teste de Causalidade de Granger no Vetor Correção de Erro (VEC) bivariado para verificar se o

²⁷ Isto é basicamente o teste de cointegração Engle – Granger (1987).

núcleo causa no sentido de Granger o IPCA e se o IPCA não causa no sentido de Granger o núcleo;

3. Por fim aplica-se o Teste da Razão de Verossimilhança (LR) para restrições nos parâmetros de cointegração no VEC, em outras palavras, aplica-se o teste conhecido na literatura internacional como “*VEC Granger Causality/Block Exogeneity Wald Tests*”, no qual é o mesmo que testar $\lambda = \theta_1 = \dots = \theta_s = 0$ na equação (31), indicando que o IPCA não deve ser um atrator para o núcleo e também que o núcleo não seja sensível a outliers observados no IPCA.

4.3.6 O Teste Diebold-Mariano para acurácia de previsão fora da amostra

Além da verificação das condições do núcleo, segundo Marques *et al.*, (2003), verifica-se também se o núcleo possui a característica de ser um bom predictor para o IPCA. Para tanto aplica-se o teste DM para acurácia de previsão fora da amostra desenvolvido por Diebold e Mariano (1995), onde são comparadas as diferentes previsões fora da amostra para o IPCA fornecidas pelos núcleos analisados e pelo próprio IPCA, indicando se duas previsões comparadas possuem estatisticamente mesma acurácia.

Dado y_t como sendo a série observada do IPCA e f_1 como sendo a previsão do núcleo IPCA_CN e f_2 como sendo a previsão de um outro núcleo. Definem-se os erros de previsões como $e_1 = f_1 - y_t$ e $e_2 = f_2 - y_t$ onde a perda associada com as previsões é assumida como sendo uma função dos erros de previsões, sendo denotada por $L(e)$, com $e = \{e_1, e_2\}$. Assume-se que a função perda $L(e)$ atende as seguintes características:

1. Assumem valor igual a zero quando nenhum erro é cometido;
2. É uma função não negativa;
3. É crescente no tamanho a medida em que os erros se tornam grandes na magnitude.

O diferencial de perda entre as previsões do núcleo *IPCA_CN* e o outro núcleo é dado por: $d = L(e_1) - L(e_2)$. As duas previsões possuem a mesma acurácia se e somente se o diferencial de perda acima tem esperança igual a zero para todo período de tempo t . A hipótese nula de mesma acurácia entre as duas previsões é dada por: $H_0: E[d_t] = 0$, contra a hipótese alternativa: $H_1: E[d_t] \neq 0$, sendo que a estatística de teste DM é dada pela fórmula:

$$DM = \frac{d}{\sqrt{\frac{2\pi f_d(0)}{T}}} \rightarrow N(0,1) \quad (32)$$

Sendo que $\underline{d} = \frac{1}{T} \sum_{t=1}^T d_t$ d_t é a média do diferencial de perda e $2\pi\hat{f}_d(0)$ é um estimador consistente da variância assintótica de $\sqrt{T}\underline{d}$. Aplica-se no presente trabalho as seguintes funções perda:

1. U-Shape: $L(e_i) = e_i^2$;
2. V-Shape: $L(e_i) = |e_i|$;
3. Linex: $L(e_i) = p \times \text{Exp}(e_i) - (1 - p \times e_i)$ onde p é o parâmetro *shape*.

4.4 Análise dos dados e resultados do modelo

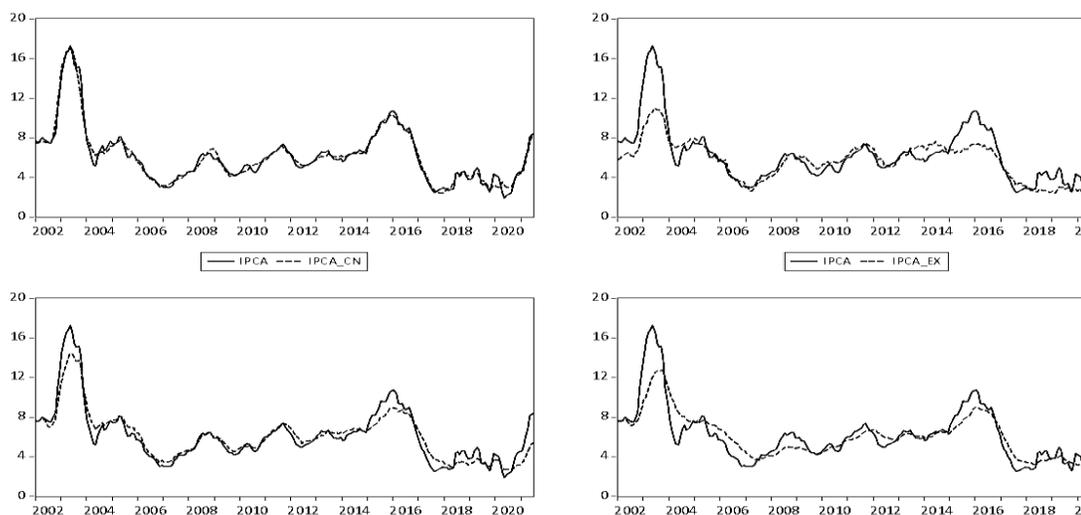
Além do núcleo estimado no presente trabalho utilizando a modelagem de componentes não observados (IPCA_CN), são utilizados outros três núcleos formulados pelo Banco Central, são eles: o núcleo por exclusão sem monitorados e alimentos no domicílio (IPCA_EX), o núcleo de dupla ponderação (IPCA_DP) e o núcleo de médias aparadas com suavização (IPCA_MS). Todas essas medidas de núcleo são calculadas para o Índice de Preços ao Consumidor Amplo (IPCA) na variação acumulada em 12 meses, dado que o Banco Central utiliza o IPCA como índice oficial adotado no sistema de metas de inflação para o ano como um todo. Conforme apresentam Silva Filho e Figueiredo (2014) para uma ampla revisão dessas medidas elaboradas pelo BCB.

De acordo com o Banco Central do Brasil (2009), a construção do núcleo por exclusão sem monitorados e alimentos no domicílio (IPCA-EX) consiste em excluir os itens dos grupos Alimentação no Domicílio e Preços Administrados por Contrato e Monitorados, enquanto o núcleo de médias aparadas com suavização (IPCA-MS) exclui 40% dos itens que apresentam grandes variações (sendo 20% de cada cauda da distribuição) e recalcula o índice de inflação utilizando apenas a parte central da distribuição. Como alguns preços controlados apresentam variações elevadas mais infrequentes, poderia haver uma eliminação sistemática desses itens, provocando uma subestimação do cálculo do núcleo. Para evitar esse problema, o BC suaviza essas variações em doze parcelas iguais, já o núcleo de dupla ponderação (IPCA-DP) inclui todos os itens, porém fornece um peso menor para aqueles que apresentam maior volatilidade. Dessa forma, os pesos originais de cada item do IPCA são ponderados novamente considerando-se a respectiva volatilidade.

O Gráfico 12 apresenta as séries em variação acumulada em doze meses do IPCA e dos núcleos para o IPCA, sendo o estimado no presente capítulo utilizando a modelagem de componentes não observados (IPCA_CN) a dos três núcleos da inflação calculados pelo BC

(IPCA_EX, IPCA_DP e IPCA_MS). Cada núcleo é apresentado no gráfico, juntamente com a série do IPCA observado, para o período de janeiro de 2002 a junho de 2021.

Gráfico 12 – IPCA observado e Núcleos para o IPCA - 2002.1 a 2021.6



Fonte: Elaboração própria.

Pode verificar que o Núcleo IPCA_CN estimado pela modelagem de componentes não observados tende a seguir uma dinâmica de trajetória de longo prazo mais próxima do IPCA, mas ao mesmo tempo tende a não seguir alguns picos e vales do IPCA que possuem um caráter de efeito transitório, atendendo assim uma das condições de núcleo que é o de minimizar os efeitos transitórios e captar com mais precisão os efeitos permanentes do índice de inflação observada. As outras três medidas seguem dinâmicas de trajetórias no tempo com menores similaridades em relação ao IPCA e com uma suavização maior dos efeitos transitórios de curto prazo em comparação com o núcleo IPCA_CN. A análise gráfica da dinâmica do núcleo em relação ao IPCA observado fornece pouca informação quanto à condição de um bom núcleo para o IPCA.

A Tabela 8 abaixo apresenta as estatísticas descritivas para o IPCA e os núcleos do IPCA. Pode-se verificar que o IPCA e o IPCA_CN possuem dispersões em torno da média maiores do que os núcleos IPCA_DP, IPCA_EX, IPCA_MS, apesar de todas essas dispersões serem consideradas altas, dado que os coeficientes de variação apresentam valores maiores do que 30%. As médias e medianas dos núcleos são muito próximas em relação às do IPCA, enquanto as amplitudes dos três núcleos do BC são consideravelmente menores do que as do IPCA e IPCA_CN.

Tabela 8 – Estatísticas descritivas para o IPCA e núcleos do IPCA

Estatística	IPCA	IPCA_CN	IPCA_DP	IPCA_EX	IPCA_MS
Média	6,144	6,140	6,041	5,537	5,909
Mediana	5,840	5,910	6,003	5,918	5,861
Máximo	17,240	17,176	14,363	10,967	12,678
Mínimo	1,880	2,435	2,598	0,900	2,313
Amplitude (Máx. - Mín.)	15,360	14,741	11,765	10,067	10,365
Desvio Padrão	2,829	2,781	2,356	2,055	2,204
Coeficiente de Variação (CV)	46,04%	45,29%	39,01%	37,11%	37,31%

Fonte: Elaboração própria.

4.4.1 Testes de raiz unitária

Para a verificação das condições de uma medida de núcleo segundo Marques *et al.*, (2003), é necessário que o IPCA e os seus respectivos núcleos sejam séries de tempo integradas de primeira ordem, $I(1)$. Foram aplicados os testes de raiz unitária Dickey-Fuller aumentado (ADF), onde a hipótese nula a ser testada é de não estacionariedade, e o teste KPSS, onde a hipótese nula a ser testada é de estacionariedade. Ambos os testes indicam que tanto os núcleos do IPCA quanto às variáveis²⁸ contidas do modelo de componentes não observados, IPCA, PIB, SELIC e M1 são $I(1)$ a um nível de 5% de significância.

Tabela 9 – Testes de raiz unitária Dickey-Fuller Aumentado (ADF) e KPSS

Variáveis	Valores Críticos ADF (τ_t)	
	1ª Diferença	Nível
<i>PIB</i>	-11,154 (**)	-1,569
<i>SELIC</i>	-6,030 (**)	-2,838
<i>M1</i>	-7,285 (**)	-1,430
<i>IPCA</i>	-4,615 (**)	-2,926
<i>IPCA_CN</i>	-5,653 (**)	-2,779
<i>IPCA_EX</i>	-4,441 (**)	-2,178
<i>IPCA_MS</i>	-4,129 (**)	-2,408
<i>IPCA_DP</i>	-4,236 (**)	-2,703
Variáveis	Valores Críticos KPSS (η_t)	
	1ª Diferença	Nível
<i>PIB</i>	0,056	0,463 (**)

²⁸ A variável PIB mensal refere-se ao índice de volume do PIB (base 2002.1=100) produzido pelo IBRE/FGV. A Selic é acumulada no mês anualizada (% a.a) e o M1 mensal refere-se ao saldo em final de período, em termos reais, deflacionado pelo IPCA com base em dezembro de 2021. O IPCA é a variação acumulada em 12 meses com periodicidade mensal. Para a aplicação no modelo transformou-se a SELIC e o M1 em índices com base em 2002.1=100. A amostra aplicada no modelo refere-se ao período de janeiro de 2002 a junho de 2021. Os gráficos dessas variáveis estão apresentados no Apêndice na Figura A.3.1.

Tabela 9 – Testes de raiz unitária Dickey-Fuller Aumentado (ADF) e KPSS – Continuação

<i>SELIC</i>	0,039	0,182 (**)
<i>MI</i>	0,146	0,261 (**)
<i>IPCA</i>	0,036	0,174 (**)
<i>IPCA_CN</i>	0,037	0,398 (**)
<i>IPCA_EX</i>	0,053	0,182 (**)
<i>IPCA_MS</i>	0,050	0,175 (**)
<i>IPCA_DP</i>	0,038	0,152 (**)

Fonte: Elaboração própria.

Notas: (**) indica rejeição da hipótese nula ao nível de 5% de significância. Os valores críticos dos testes ADF e KPSS, com constante e tendência, são baseados nos trabalhos de MacKinnon (1996) e de Kwiatkowski *et al.*, (1992), respectivamente.

4.4.2 Análise das Condições para o núcleo segundo Marques *et al.*, (2003)

Após a verificação de que tanto o IPCA quanto os seus núcleos são $I(1)$, analisa-se nessa seção as condições para o núcleo segundo Marques *et al.*, (2003). A condição de que a taxa de inflação e a medida de núcleo devem exibir uma tendência comum, isto é, para que o núcleo não forneça uma sinalização errada do comportamento de longo prazo da taxa de inflação, será verificada com a aplicação dos testes de cointegração Engle e Granger (1987) e Phillips e Ouliaris (1990), baseados na estacionariedade dos resíduos das regressões bivariadas entre duas variáveis $I(1)$, no caso o IPCA e o seu núcleo. A Tabela 10, abaixo, apresenta os resultados dos testes de cointegração.

Tabela 10 – Testes de cointegração bivariado

Teste de Cointegração	H0: não existe cointegração entre <i>IPCA</i> e <i>IPCA_CN</i>	H0: não existe cointegração entre <i>IPCA</i> e <i>IPCA_DP</i>	H0: não existe cointegração entre <i>IPCA</i> e <i>IPCA_EX</i>	H0: não existe cointegração entre <i>IPCA</i> e <i>IPCA_MS</i>
Engle-Granger	$\tau_t = -9,437$ (0,000)	$\tau_t = -3,486$ (0,110)	$\tau_t = -3,998$ (0,032)	$\tau_t = -3,471$ (0,113)
Phillips-Ouliaris	$\tau_t = -4,849$ (0,002)	$\tau_t = -2,798$ (0,367)	$\tau_t = -2,733$ (0,400)	$\tau_t = -3,697$ (0,068)

Fonte: Elaboração própria.

Notas: Os valores críticos τ_t , com constante e tendência, e os P-valores apresentados em parênteses são baseados nos trabalhos de MacKinnon (1996). As escolhas das ordens de defasagens foram determinadas a partir da minimização do critério de Hannan-Quinn.

De acordo com a Tabela 10, apenas o núcleo *IPCA_CN* apresentou cointegração com o IPCA nos dois testes com um nível de 5% de significância. Já o *IPCA_EX* apresentou cointegração, segundo o teste Engle-Granger, com um nível de 5% de significância. Verifica-se, portanto, que há evidência de que apenas o *IPCA_CN* e *IPCA_EX* apresentam uma

tendência comum de longo prazo em relação ao IPCA. Dada a análise de cointegração, verifica-se a seguir o teste de causalidade de Granger aplicado ao VEC.

Tabela 11 – Teste de causalidade de Granger aplicado ao VEC

Direção da Causalidade	IPCA_CN	IPCA_DP	IPCA_EX	IPCA_MS
<i>IPCA</i> Núcleo não causa <i>IPCA</i>	16,971	4,606	4,466	5,690
<i>IPCA</i> não causa <i>IPCA</i> Núcleo	0,000	0,203	0,107	0,128
	2,445	8,912	32,453	58,390
	0,295	0,031	0,000	0,000

Fonte: Elaboração própria.

Nota: As escolhas das ordens de defasagens foram determinadas a partir na minimização do critério de Hannan-Quinn.

A Tabela 11 fornece os resultados para o teste de causalidade de Granger, indicando que apenas o núcleo do IPCA estimado no presente trabalho utilizando a modelagem de componentes não observados (IPCA_CN), atende as condições de causar no sentido de Granger o IPCA e de o IPCA não causar no sentido de Granger o núcleo IPCA_CN, em ambos os casos com um nível de significância de 5%. Ainda que o núcleo IPCA_EX mostrou-se cointegrado com o IPCA, de acordo com o teste Engle-Granger, por outro lado, esse núcleo não causa no sentido de Granger o IPCA. Por fim, a seguir será verificada se a condição de que o IPCA não deve ser um atrator para o núcleo e que o núcleo não seja sensível a outliers observados no IPCA é atendida.

Tabela 12 – Teste da razão de verossimilhança (LR) para restrições nos parâmetros de cointegração

Variável Dependente	Teste LR (χ^2)	P-Valor
Δ <i>IPCA_CN</i>	0,015	0,903
Δ <i>IPCA_DP</i>	5,383	0,020
Δ <i>IPCA_EX</i>	0,000	0,985
Δ <i>IPCA_MS</i>	1,600	0,206

Fonte: Elaboração própria.

Notas: Teste conhecido na literatura como “VEC *Granger Causality/Block Exogeneity Wald Tests*”; Δ significa operador de primeira diferença. As escolhas das ordens de defasagens foram determinadas a partir da minimização do critério de Hannan-Quinn.

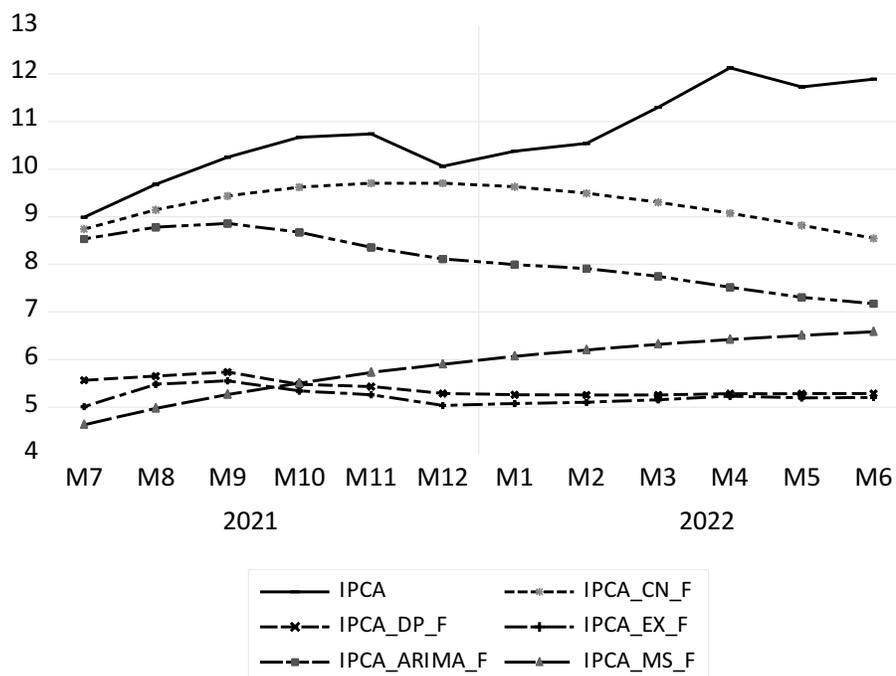
De acordo com a Tabela 12, na qual estão os resultados para o teste da Razão de Verossimilhança (LR) para restrições nos parâmetros de cointegração, pode-se verificar que não rejeita-se a hipótese nula $\lambda = \theta_1 = \dots = \theta_s = 0$) tomando como variável dependente a primeira diferença de IPCA_CN, indicando, com 5% de significância, que o IPCA não é um atrator para o núcleo IPCA_CN e também que o núcleo IPCA_CN não é sensível a outliers observados no IPCA.

Pode-se verificar que o núcleo do IPCA estimado pela modelagem de componentes não observados (IPCA_CN) é o único que atende a todas as condições para uma medida de núcleo apresentadas em Marques *et al.*, (2003). Essas condições atendidas, atreladas ao fato desse núcleo ser estimado por modelagem, no qual incorpora informações do comportamento de variáveis macroeconômicas importantes, como o produto interno bruto, PIB, a taxa de juros Selic e a oferta monetária M1, faz dele um núcleo que provavelmente apresente a característica *forward looking*, isto é, de ser um bom previsor do IPCA.

4.4.3 Resultados das previsões e Acurácia fora da amostra dos núcleos

Nessa seção serão apresentadas as previsões fora da amostra dos núcleos com o intuito de prever o índice de inflação IPCA. Aplicou-se também a previsão da própria taxa de inflação IPCA. As previsões foram realizadas utilizando a metodologia ARIMA onde as escolhas das ordens de defasagens foram determinadas a partir da minimização do critério de Hannan-Quinn. A amostra para a realização das previsões contempla o período de janeiro de 2002 a junho de 2021, enquanto a previsão fora da amostra é para doze meses à frente, para o período de julho de 2021 a junho de 2022.

O gráfico 13 apresenta as previsões fora da amostra dos núcleos e do próprio IPCA, para o período 2021.7 a 2022.6, comparando-as com o IPCA observado. Pode-se verificar que o núcleo IPCA_CN foi a previsão que mais se aproximou do IPCA observado, principalmente para o período 2021.7 a 2021.12. Além dessa análise inicial das trajetórias das previsões, é necessária a análise das medidas de erro de previsão, no qual são apresentadas na Tabela 13.

Gráfico 13 – IPCA observado e previsões fora da amostra dos núcleos

Fonte: Elaboração própria.

Notas: Previsões utilizando a modelagem ARIMA, onde as escolhas das ordens de defasagens foram determinadas a partir da minimização do critério de Hannan-Quinn. A variável *IPCA* representa o IPCA observado enquanto *IPCA*_F* e *IPCA_ARIMA_F* representam as previsões do IPCA utilizando os núcleos e o IPCA observado, respectivamente.

A Tabela 13 apresenta um conjunto das principais medidas de erro de previsão, com o objetivo de avaliar o desempenho dos núcleos em prever o IPCA observado. A avaliação é realizada em quatro diferentes períodos fora da amostra, 3 períodos à frente (2021:07-2021:09), 6 períodos à frente (2021:07-2021:12), 9 períodos à frente (2021:07-2022:03) e 12 períodos à frente (2021:07-2022:06).

Tabela 13 – Avaliação das previsões fora da amostra para o IPCA

Avaliação das previsões de 3 períodos à frente (2021:07-2021:09)						
Medidas de Erro de Previsão						
Variáveis Previstas	RMSE	MAE	MAPE	SMAPE	Theil U1	Theil U2
<i>IPCA_CN_F</i>	0,580	0,534	5,425	5,600	0,031	1,064
<i>IPCA_DP_F</i>	4,013	3,989	41,248	52,024	0,262	6,683
<i>IPCA_EX_F</i>	4,306	4,295	44,522	57,283	0,287	6,968
<i>IPCA_ARIMA_F</i>	0,993	0,917	9,331	9,856	0,054	1,812
<i>IPCA_MS_F</i>	4,692	4,685	48,595	64,192	0,321	7,593
Avaliação das previsões de 6 períodos à frente (2021:07-2021:12)						
Medidas de Erro de Previsão						

Tabela 13 – Avaliação das previsões fora da amostra para o IPCA – Continuação

Variáveis Previstas	RMSE	MAE	MAPE	SMAPE	Theil U1	Theil U2
<i>IPCA_CN_F</i>	0,743	0,674	6,550	6,815	0,038	1,447
<i>IPCA_DP_F</i>	4,588	4,541	44,887	58,052	0,294	8,616
<i>IPCA_EX_F</i>	4,819	4,788	47,424	62,266	0,314	8,947
<i>IPCA_ARIMA_F</i>	1,656	1,514	14,720	16,115	0,089	3,171
<i>IPCA_MS_F</i>	4,747	4,733	47,045	61,590	0,308	8,786

Avaliação das previsões de 9 períodos à frente (2021:07-2022:03)						
Medidas de Erro de Previsão						
Variáveis Previstas	RMSE	MAE	MAPE	SMAPE	Theil U1	Theil U2
<i>IPCA_CN_F</i>	0,998	0,871	8,241	8,696	0,051	1,967
<i>IPCA_DP_F</i>	4,911	4,856	46,926	61,536	0,312	9,558
<i>IPCA_EX_F</i>	5,109	5,069	49,077	65,176	0,329	9,877
<i>IPCA_ARIMA_F</i>	2,153	1,962	18,639	20,949	0,115	4,234
<i>IPCA_MS_F</i>	4,685	4,671	45,459	58,942	0,294	9,007

Avaliação das previsões de 12 períodos à frente (2021:07-2022:06)						
Medidas de Erro de Previsão						
Variáveis Previstas	RMSE	MAE	MAPE	SMAPE	Theil U1	Theil U2
<i>IPCA_CN_F</i>	1,779	1,430	12,694	14,015	0,089	3,236
<i>IPCA_DP_F</i>	5,394	5,300	49,111	65,437	0,334	10,201
<i>IPCA_EX_F</i>	5,553	5,479	50,879	68,465	0,348	10,466
<i>IPCA_ARIMA_F</i>	2,956	2,618	23,602	27,630	0,157	5,483
<i>IPCA_MS_F</i>	4,879	4,857	45,454	58,908	0,294	9,212

Fonte: Elaboração própria.

Notas: RMSE: Raiz do Erro Quadrático Médio; MAE: Erro Absoluto médio; MAPE: Erro Percentual Absoluto Médio; SMAPE: Erro Percentual Absoluto Médio Simétrico; Theil U1 e U2: Estatísticas de desigualdade de Theil.

Previsões utilizando a modelagem ARIMA, onde as escolhas das ordens de defasagens foram determinadas a partir da minimização do critério de Hannan-Quinn. A variável *IPCA* representa o IPCA observado enquanto *IPCA*_F* e *IPCA_ARIMA_F* representam as previsões do IPCA utilizando os núcleos e o IPCA observado, respectivamente.

De acordo com os resultados apresentados na Tabela 13, pode-se verificar que o núcleo gerado pela modelagem de componentes não observados, *IPCA_CN*, forneceu os menores valores em todas as medidas de erro de previsão para todos os 4 diferentes períodos. O segundo melhor desempenho preditivo foi apresentado pela previsão do próprio IPCA, enquanto os três núcleos calculados pelo BCB registraram erros de previsão bem superiores às previsões do *IPCA_CN* e do próprio IPCA. Dado que o núcleo *IPCA_CN* mostrou-se ser o melhor predictor dentre os núcleos testados, mesmo ainda em comparação com as previsões do próprio IPCA. Nesse caso, testa-se a comparação de acurácia preditiva entre as previsões do *IPCA_CN* e as outras previsões, para o período de doze meses à frente (2021:07-2022:06) utilizando o teste Mariano e Diebold, como apresentado na Tabela 14.

Tabela 14 – Teste de comparação de acurácia preditiva Diebold–Mariano para o núcleo *IPCA_CN* no período 2021.07-2022.06

H0: As previsões do <i>IPCA_CN</i> e do <i>IPCA_*</i> possuem a mesma acurácia						
Previsões	Funções Perda					
	U-Shape		V-Shape		Linex	
	Estatística DM	P-Valor	Estatística DM	P-Valor	Estatística DM	P-Valor
<i>IPCA_ARIMA</i>	-2,711	0,020	-4,715	0,001	-3,916	0,002
<i>IPCA_DP</i>	-7,479	0,000	-19,645	0,000	-17,164	0,000
<i>IPCA_EX</i>	-8,644	0,000	-20,793	0,000	-20,530	0,000
<i>IPCA_MS</i>	-17,821	0,000	-9,063	0,000	-10,971	0,000

Fonte: Elaboração própria.

Nota: Teste aplicado com o fator de correção HLN, apresentado em Harvey, Leybourne e Newbold (1997), para o cálculo dos desvios padrões com correção de viés para pequenas amostras.

Com efeito, aplica-se o teste DM para acurácia de previsão fora da amostra desenvolvido por Diebold e Mariano (1995), onde são comparadas as diferentes previsões fora da amostra para o IPCA fornecidas pelos núcleos analisados e pelo próprio IPCA, indicando se duas previsões comparadas possuem estatisticamente mesma acurácia. Dado que o núcleo *IPCA_CN* forneceu os menores erros de previsão, aplicou-se o teste DM nas previsões fora da amostra desse núcleo em comparação com as previsões dos outros núcleos e com a previsão do próprio IPCA, onde os resultados da Tabela 14 acima indicam que rejeita-se a hipótese nula de mesma acurácia a uma significância de 5%, em todas as comparações e em todas as funções perdas (U-Shape, V-Shape e Linex), para o período fora da amostra de julho de 2021 a junho de 2022, isto é, as previsões realizadas pelo *IPCA_CN* para esse período²⁹ possuem acurácia diferente das previsões dos núcleos e do próprio IPCA, confirmando que os menores erros de previsão apresentados na Tabela 13 indicam que o *IPCA_CN* é o melhor predictor para o IPCA observado.

Alguns dos resultados do presente capítulo em relação aos núcleos do BC analisados vão de encontro aos resultados de Santos e Castelar (2016), os quais avaliaram os principais núcleos produzidos pelo BC, concluindo que o núcleo por exclusão sem monitorados e alimentos no domicílio (*IPCA-EX*) e o núcleo de dupla ponderação (*IPCA-DP*), não indicaram a trajetória da dinâmica de ajustamento esperada, enquanto o *IPCA-DP* mostrou-se enviesado em relação à inflação. Já em relação à capacidade preditiva, não se obteve resultados

²⁹ Apresentou-se apenas o resultado do teste DM para doze meses fora da amostra, 2021:7-2022:6, maior amostra possível, dado que os tamanhos para os outros períodos são menores, não sendo adequados para a robustez do teste, ainda que se aplique o fator de correção para pequenas amostras HLN, como apresentado em Harvey, Harvey, Leybourne e Newbold (1997). Ainda assim o teste DM foi aplicado para os outros períodos, indicando o mesmo resultado de acurácias diferentes.

consistentes no sentido de que as previsões de longo prazo obtidas com os núcleos do BC sejam mais precisas do que as previsões que se obtêm com a própria inflação.

4.5 Conclusão

O presente ensaio consistiu na construção de uma medida de núcleo para o índice de inflação IPCA utilizando como metodologia um modelo multivariado de componentes não observados seguindo Koopman e Harvey (2009). O modelo é composto pelas variáveis macroeconômicas PIB real, taxa de juros SELIC nominal, oferta do agregado monetário M1 em termos reais e a taxa de inflação IPCA. O núcleo gerado pelo modelo de componentes não observados (IPCA_CN) corresponde a tendência estocástica estimada para o IPCA. Esta medida de núcleo gerada por modelagem multivariada tem a vantagem de ter características *forward-looking*, e contém informações dos dois principais mecanismos de política monetária para o controle da meta inflacionária: os controles da SELIC e da oferta monetária M1.

Comparou-se a medida de núcleo IPCA_CN com três outros núcleos produzidos pelo Banco Central do Brasil (BCB), o núcleo por exclusão sem monitorados e alimentos no domicílio (IPCA_EX), o núcleo de dupla ponderação (IPCA_DP) e o núcleo de médias aparadas com suavização (IPCA_MS). Primeiro aplicou-se as condições para uma medida de núcleo segundo Marques *et al.*, (2003), no qual indicou que apenas a medida de núcleo gerada pela modelagem de componentes não observados (IPCA_CN) mostrou-se ser não enviesada e comportando-se como um indicador antecedente para o IPCA. Os resultados apresentados conformam-se com os de Marques *et al.*, (2003), pois todas as medidas de núcleo produzidas pelas autoridades monetárias de um conjunto de países mostraram-se enviesadas ou não antecedem a taxa de inflação.

Previsões fora da amostra foram realizadas confirmando que o núcleo IPCA_CN possui um poder preditivo superior às previsões dos núcleos do BC testados e a previsão do próprio IPCA observado, dado os menores erros de previsão e a confirmação de melhor acurácia indicado pelo teste Diebold-Mariano.

O trabalho de Marques *et al.*, (2003) mostra porque a medida por exclusão, que é a mais utilizada pelas autoridades monetárias, não deve ser utilizada como um indicador antecedente para a taxa de inflação. Apesar da medida de núcleo IPCA_CN apresentada ser de compreensão mais complexa e precisar de constante revisão, ela possui a vantagem de não implementar escolhas arbitrárias nas identificações e exclusões dos choques transitórios. Esta medida de núcleo IPCA_CN também possui a vantagem de conter informações de política

monetária e de ser um bom indicador antecedente para previsão da taxa de inflação. Portanto, seria interessante que o BC produza núcleos baseados em modelagem multivariada que apresentem boa performance em previsão fora da amostra.

REFERÊNCIAS

ACOSTA, M. A. Machine learning core inflation. **Economics letters**, v.169, n.1, p. 47-50, 2018.

AKBAR, M.; JABBAR, A. Impact of macroeconomic policies on national food security in Pakistan: simulation analyses under a simultaneous equations framework. **Agricultural economics (Czech Republic)**, v. 63, n.10, p. 471-484, 2017.

ALBEROLA-ILA, E. et al. Output gaps and policy stabilisation in Latin America: the effect of commodity and capital flow cycles. **BIS Working Papers**, n. 568, p. 47-64, 2016. Disponível em: <https://www.bis.org/publ/work568.htm>. Acesso em: 23 mai. 2019.

ALESSI, L.; BARIGOZZI, M.; CAPASSO, M. Improved penalization for determining the number of factors in approximate factor models. **Statistics and Probability Letters**, v. 80, n.23, p.1806-1813, 2010.

AMATOV, A.; DORFMAN, J.H. The effects on commodity prices of extraordinary monetary policy. **Journal of Agricultural and Applied Economics**, v. 49, 1 p.83–96, 2017. Disponível em: <https://www.cambridge.org/core/journals/journal-of-agricultural-and-applied-economics/article/effects-on-commodity-prices-of-extraordinary-monetary-policy/7064CC5BDC6D44837E1C42B5374BA650>. Acesso em: 4 mai. 2019.

ANZUINI, A. et al. The impact of monetary policy shocks on commodity prices. **International Journal of Central Banking**, v. 9, n.3, p.125-150, 2013. Disponível em: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1232.pdf> . Acesso em: 13 mai. 2020.

AOKI, K. Optimal monetary policy responses to relative-price changes. **Journal of Monetary Economics**, n.48, p.55–80, 2001. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0304393201000691>. Acesso em: 12 ago 2019.

ARRUDA, A, F. **Macroeconomia e preços de commodities agrícolas**. Dissertação (mestrado), Escola Superior de Agricultura Luiz de Queiroz, São Paulo, 2008. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11132/tde-24072008-123523/pt-br.php>. Acesso em: 13 mai 2020.

ASFAHA, T. A.; JOOSTE, A. The Effect of Monetary Changes on Relative Agricultural Prices. **Agrekon**, v.46, n.4, p.460-474, 2007. Disponível em: <https://doi.org/10.1080/03031853.2007.9523781>. Acesso em: 23 jul. 2019.

AWOKUSE, T, O. Impact of macroeconomic policies on agricultural prices Agricultural and Resource. **Economics Review**, v. 34, n.2, p. 226-237, 2005. Disponível em: <https://www.cambridge.org/core/journals/agricultural-and-resource-economics-review/article/abs/impact-of-macroeconomic-policies-on-agricultural-prices/93C85946E95B90F36894BD604E7C877E>. Acesso em: 12 dez. 2019.

- BACIO, Cristian, Ionut. Measures of core inflation used by the national bank of Romania. **CES Working Papers**, v.7, n.1, p.17-30, 2015. Disponível em: https://ceswp.uaic.ro/articles/CESWP2015_VIII_BAC.pdf. Acesso em: 13 mai. 2020.
- BAGLIANO, F.C.; GOLINELLI, R.; MORANA, C. Core inflation in the Euro Area. **Applied Economics Letters**, v. 9, p. 353-357, 2002. Disponível em: <https://econpapers.repec.org/article/tafapect/>..Acesso em: 13 mai. 2020.
- BALCILAR, M. et al. The relationship between oil and agricultural commodity prices in South Africa: a quantile causality approach. **The Journal of Developing Areas**, v.50, n.2, p.137-152, 2016. Disponível em: <https://repository.up.ac.za/handle/2263/60921>. Acesso em: 18 jul. 2020.
- BANCO CENTRAL DO BRASIL. Novas medidas de núcleo de inflação. **Estudo especial**, Brasília, v.20, n.17, p. 1 – 16, 2018.
- BARBOSA FILHO, F. H. A crise econômica de 2014/2017. **Estudos Avançados**, v.31, n.89, p.51-60, 2017. Disponível em: <https://doi.org/10.1590/s0103-40142017.31890006>. Acesso em: 13 mai. 2021.
- BELKE, A.; REES, A. Globalisation and Monetary Policy: a FAVAR Analysis for the G7 and the Euro zone. **North American Journal of Economics and Finance**, v.29, p.306-32, 2014.
- BERNANKE, B. S et al. Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach. **The Quarterly Journal of Economics**, v. 120, n. 1, p.387-422, 2005. Disponível em: <https://academic.oup.com/qje/article-abstract/120/1/387/1931468?redirectedFrom=fulltext>. Acesso em: 18 mai. 2020.
- BEVERIDGE, S.; NELSON, C. R. A New Approach to Decomposition of Economic Time Series into Permanent and Transitory Components with Particular Attention to Measurement of the Business Cycle. **Journal of Monetary Economics**, v. 7, p. 151-174, 1981. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/0304393281900404>. Acesso em: 23 jun. 2019.
- BHATTACHARYA, R. Effectiveness of monetary policy in stabilising food inflation: Evidence from advanced and emerging economies. **NIPFP Working Paper Series**, n. 209, p. 2-40, 2017. Disponível em: <http://www.nipfp.org.in/publications/working-papers/1796/>. Acesso em: 13 dez. 2020.
- BLACK, C. Preços das commodities, termos de troca e crescimento econômico brasileiro nos anos 2000. **Indic. Econ. FEE**, Porto Alegre, v. 42, n.3, p. 27-44, 2015. Disponível em: <file:///C:/Users/Lucia%20Sindeaux/Downloads/3466-20891-1-PB.pdf>. Acesso em: 12 fev. 2019.
- BLINDER, A. Commentary. **Federal Reserve Bank St. Louis**, v. 79, p.157-160, 1997.

BLOOM, N. Observations on uncertainty. **Australian economic review**, v.50, n.1, p. 79–84, 2017. Disponível em: <https://doi.org/10.1111/1467-8462.12203>. Acesso em: 20 mar. 2020.

BRASIL. IBGE – Instituto Brasileiro de Geografia e Estatística. PIB cresce 1,1% e fecha 2019 em R\$ 7,3 trilhões. 2020. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/27007-pib-cresce-1-1-e-fecha-2019-em-r-7-3-trilhoes>. Acesso em: 20 jul. 2021.

BREDOW, S. M. S et al. O ciclo de alta nos preços das commodities e a economia brasileira: uma análise dos mecanismos externos de transmissão entre 2002 e 2014. **Economia e Sociedade**, Campinas, v.25, n.3, p.695-731, 2016. Disponível em: <https://www.scielo.br/j/ecos/a/djLQqMkmpMdgHtnK7f46Rdf/?format=pdf&lang=pt>. Acesso em: 20 jan. 2020.

BUENO, R. L. S. **Economia de séries temporais**. São Paulo: Cengage, 2008.

BURNS, A.; MITCHELL, W. **Measuring business cycles**. New York:National Bureau of economic Research, 1946.

CATÃO, L. A.V.; CHANG, R. World food prices and monetary policy. **Journal of Monetary Economics**, n. 75, p.69–88, 2015. Disponível em: <https://econweb.rutgers.edu/rchang/JME13-096-paper.pdf>. Acesso em: 6 fev. 2019.

CHEN, H.; TSANG, A. Impact of US monetary policy rate shock and other external shocks on the Hong Kong economy: A factor-augmented vector autoregression approach. **Pacific Economic Review**, v.25, n.1, p.3-20, 2018. Disponível em: <https://doi.org/10.1111/1468-0106.12262>. Acesso em: 20 abr. 2020.

CHEUNG, C. Are commodity prices useful leading indicators of inflation? **Working Paper, Bank of Canada** n. 5, p.1-29, 2009. Disponível em: <https://www.bankofcanada.ca/wp-content/uploads/2010/01/dp09-5.pdf>. Acesso em: 2 out. 2019.

CHEUNG, T. O. Impact of macroeconomic policies on agricultural prices. **Agricultural and Resource Economics Review**, v. 34, n.2, p. 226-237, 2005. Disponível em: <https://www.cambridge.org/core/journals/agricultural-and-resource-economics-review/article/abs/impact-of-macroeconomic-policies-on-agricultural-prices/93C85946E95B90F36894BD604E7C877E>. Acesso em: 12 set. 2021.

CRONE, Theodore. M et al. Core measures of inflation as predictors of total inflation. **Journal of Money, Credit, and Banking**, v.45, n. 3, p. 505-519, 2013.

DA SILVA FILHO, T. N. T et al. Revisitando as Medidas de Núcleo de Inflação do Banco Central do Brasil. **Working Papers Series**, Brasília, n. 356, p. 1-30, 2014. Disponível em: <https://www.bcb.gov.br/pec/wps/port/TD356.pdf>. Acesso em: 20 dez. 2018.

DIEBOLD, F.X.; MARIANO R. Comparing predictive accuracy. **Journal of business economic statistics** 13, p. 253-265, 1995. Disponível em:

https://econpapers.repec.org/article/besjnlbes/v_3a13_3ay_3a1995_3ai_3a3_3ap_3a253-63.htm. Acesso em: 23 jun. 2019.

DORNBUSCH, R. Expectations and Exchange Rate Dynamics. **Journal of Political Economy**, n. 84, p. 1161–76, 1976. Disponível em: <https://www.jstor.org/stable/1831272>. Acesso em: 1 mai. 2019.

DURBIN, J. KOOPMAN, S. J. **Time series analysis by state space methods**. UK: Oxford:Oxford Univ. Press, 2001.

ENDERS, W. **Applied econometric time series**. 3 ed. USA: Univ. of Alabama, 2010.

ENGEL, C.; J. D. HAMILTON. Long Swings in the Dollar: Are They in the Data and Do Markets Know It? **American Economic Review**, n.80, p. 689–713, 1990.

ENGLE, ROBERT F.; GRANGER, C. W.J. co-Integration and Error Correction: representation, estimation, and testing. **Econometrica**, v. 55, n. 2, p. 251 – 276, 1987.

FERNALD, J. G. et al. Monetary policy effectiveness in China: Evidence from a FAVAR model. **Journal of International Money and Finance**, v.49, p. 83-103, 2014. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261560614000849>. Acesso em: 13 dez. 2020.

GAMBER, Edward, N *et al.* The dynamic relationship between core and headline inflation. **Citation Data Journal of Economics and Business**, v.81, p. 38-53, 2015. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0148619515000247>. Acesso em: 3 mai. 2020.

GILBERT, C.L. How to understand high food prices. **Journal of Agricultural Economics**, v.61, n.2, p. 398-425, 2010. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1477-9552.2010.00248.x>. Acesso em: 12 mai. 2020.

GONZÁLEZ, A. *et al.* Forecasting inflation with gradual regime shifts and exogenous information, **Working paper**, n 1363, p.1-47, 2011. Disponível em: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1363.pdf?abec9fe54e05fccf88a33105f42177b2>. Acesso em: 5 dez. 2020.

GOSPODINOV, N.; NG, S. Commodity prices, convenience yields, and inflation. **The Review of Economics and Statistics**, v. 95, n.1, p. 206-219, 2013. Disponível em: <https://www.jstor.org/stable/23355660>. Acesso em: 13 abr. 2020.

GREMAUD, A.P.; VASCONCELLOS, M A S.; TONETO JUNIOR, R. **Economia brasileira contemporânea**. São Paulo: Atlas, 2014.

HARDING, D.; PAGAN, A. Dissecting the cycle: a methodological investigation. **Journal of monetary economics**, v. 49, n. 2, p. 365-381, 2002. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0304393201001088>. Acesso em: 10 mai 2019.

HARVEY, D.; LEYBOURNE, S.; NEWBOLD, P. Testing the Equality of Prediction Mean Squared Error, **International Journal of Forecasting**, v.13, n. 2, p. 281-291, 1997.

HASSAN, A.F.M.; SALIM, R.A. Is there any link between commodity price and monetary policy? Evidence from Australia. **Economic Analysis and Policy**, v.41, n.3, p. 205-216, 2011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0313592611500335>. Acesso em: 23 mai. 2020.

HATZENBUEHLER, P. L.; ABBOTT, P. C.; FOSTER, K.; A. Agricultural Commodity Prices and Exchange Rates under Structural Change. **Journal of Agricultural and Resource Economics**, v.41, n.2, p. 204-224, 2016. Disponível em: <https://www.jstor.org/stable/44131335>. Acesso em: 12 mai. 2019.

KHUNDRAKPAM, J.; K.; DAS, D. Monetary Policy and Food Prices in India. Published in: **RBI Working Paper Series**, v. 12, p. 1-20, 2011. Disponível em: <https://ideas.repec.org/p/pramprapa/50904.html>. Acesso em: 9 jun. 2020.

KIM, J.; KIM, S. Effects of Monetary policy shocks on farm prices and exchange rates in Korea. **Emerging Markets finance & trade**, v.53, n.11, p.2450-2462, 2017. Disponível em: <https://ideas.repec.org/a/mes/emfitr/v53y2017i11p2450-2462.html>. Acesso em: 2 mai. 2019.

KOOPMAN, S. J.; HARVEY, A.C. Unobserved components models in economics and finance: the role of the Kalman filter in time series econometrics. **IEEE Electronic Library (IEL) Journals**. v.29, n. 6, p.71-81, 2009.

KOSE, N *et al.* Performance of inflation targeting in retrospect. **Empirica Economic**, v. 45, p.197-213, 2018. Disponível em: [Performance of inflation targeting in retrospect | SpringerLink](#). Acesso em: 12 mar. 2020.

KULAKSIZOGLU, T. Measuring the Turkish core inflation with a shifting mean model. **Empirica Economic**, v. 51, p. 57-70, 2016. Disponível em: <https://link.springer.com/article/10.1007/s00181-015-0993-0> Acesso em: 15 dez. 2020.

LANTERI, L. Determinants of real prices of agricultural commodities. The role of inventories and macroeconomic factors. **Lect. Econ**. n. 77, p.189-217 2012. Disponível em: http://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S0120-25962012000200006&lng=es&nrm=iss&tlng=en. Acesso em: 2 mai. 2019.

LÉLIS, M. T. C *et al.* Desempeno de las exportaciones de China y el Brasil hacia América Latina, 1994-2009. **Revista Cepal**, n. 106, p. 57-77, 2012. Disponível em: <https://repositorio.cepal.org/handle/11362/11526>. Acesso em: 13 mai. 2021.

LENTEN, L. J. A.; RULLI, D. N. A time-series analysis of the demand for life insurance companies in Australia: An unobserved components approach. **Australian Journal of**

- Management**, v.31, n. 1, p. 41–66, 2006. Disponível em:
<https://doi.org/10.1177/031289620603100104>. Acesso em: 23 ago. 2020.
- LOMBARDI, M. et al. Global commodity cycles and linkages: a FAVAR approach. **Empirical Economics**, v.43, n. 2, p.651-670, 2012.
- MACKINNON, J.G. Numerical Distribution Functions for Unit Root and Cointegration Tests. **Journal of applied econometrics**, n. 2, p. 601-618, 1996. Disponível em:
<https://www.jstor.org/stable/2285154>. Acesso em: 13 dez. 2020.
- MAGALHÃES, M. A. Preços de commodities e nível de atividade em uma pequena economia aberta: evidências empíricas para o estado do Espírito Santo. **Economia e sociedade**, São Paulo, v. 20, n.3, p.533-566, 2011.
- MARCO A. F. H. CAVALCANTI. Identificação de modelos VAR e causalidade de Granger: uma nota de advertência. **Econ. Apl**, Rio de Janeiro, v. 14, n. 2, p. 251 – 260, 2010. Disponível em: <https://doi.org/10.1590/S1413-80502010000200008>. Acesso em: 12 mai 2019
- MARGARIDO, M. A et al. Análise do Mecanismo de Transmissão dos Preços Internacionais de Commodities Agrícolas Sobre o Comportamento da Taxa de Câmbio Real no Brasil. Escola de Economia de São Paulo da Fundação Getúlio Vargas FGV-EESP, 2010. Disponível em:
https://www5.pucsp.br/eitt/downloads/viii_ciclo_debate/VIII_Ciclo_2010_Art_Mario_Margarido.pdf . Acesso em: 23 ago 2021.
- MARQUES C.R et al. Why should central banks avoid the use of the underlying inflation indicator? **Economics Letters**, v. 75, p. 17-23, 2002. Disponível em:
<https://www.bportugal.pt/sites/default/files/anexos/papers/wp200005.pdf>. Acesso em: 9 fev. 2020.
- MARQUES C.R. Evaluating core inflation indicators. **Economic modelling**, v. 20, n. 4, p. 765-775, 2003. Disponível em: <https://ideas.repec.org/a/eee/ecmode/v20y2003i4p765-775.html>. Acesso em: 2 jan. 2020.
- MARTINEZ, T. S. A dinâmica da inflação brasileira: considerações a partir da desagregação do IPCA. **IPEA**, Brasília, n.101, p.1-29, 2011. Disponível em:
https://repositorio.ipea.gov.br/bitstream/11058/3549/1/Comunicados_n101_Infla%c3%a7%c3%a3o.pdf. Acesso em: 2 mai. 2019.
- MEYER, B.; GUHAN, V. Trimmed-mean inflation statistics: just hit the one in the middle. Federal Reserve Bank of Cleveland, **Working paper**, n. 12, p.11-18, 2014. Disponível em:
<https://www.atlantafed.org/-/media/documents/research/publications/wp/2014/wp1403.pdf>. Acesso em: 2 jan. 2020.
- MEYER, B.; ZAMAN, S. The usefulness of the median CPI in Bayesian VARs used for macroeconomic forecasting and policy. **Empirica economic**, v. 57, p. 603–630, 2019. Disponível em: <https://doi-org.ez11.periodicos.capes.gov.br/10.1007/s00181-018-1472-1>. Acesso em: 2 jan. 2020.

MEYER, B.H *et al.* Simple ways to forecast inflation: what works best? Federal Reserve Bank of Cleveland. **Economic commentary**, n.1, p. 1-6, 2010. Disponível em: <https://www.clevelandfed.org/publications/economic-commentary/2010/ec-201017-simple-ways-to-forecast-inflation-what-works-best>. Acesso em: 2 jan. 2020.

NAZLIOGLU, S.; SOYTAS, U. World oil prices and agricultural commodity prices: evidence from an emerging market. **Energy Economics**, v. 33, n. 3, p. 488-496, 2011. Disponível em: https://econpapers.repec.org/article/eeeeneeco/v_3a33_3ay_3a2011_3ai_3a3_3ap_3a488-496.htm. Acesso em: 9 out. 2019.

ÖĞÜNÇ, F. et al. Short-term inflation forecasting models for Turkey and a forecast combination analysis. **Econ. Modell**, v. 33, p. 312-325, 2013. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264999313001314>. Acesso em: 12 dez. 2020.

PHILLIPS, P.C B.; OULIARIS, S. Asymptotic properties of residual based tests for cointegration. **Econometrica**, v. 58, n. 1, p.165-193, 1990.

PHIRI, A. Inflation persistence in BRICS countries: A quantile autoregressive (QAR) approach. **Business and economic horizons**, v. 14, n. 1, p.97-98, 2018.

POURROY, M.; CARTON, B.; COULIBALY, D. Food prices and inflation targeting in emerging economies. **International economics**, n.146, p.108–140, 2016. Disponível em: http://www.cepii.fr/PDF_PUB/wp/2012/wp2012-33.pdf. Acesso em: 23 fev. 2020.

REIGL, N. Previsão da taxa de inflação na Estônia usando modelos de fatores. **Baltic Journal of Economics**, v.17, n. 2, p.152-189, 2017.

ROGER, S. Core inflation: concepts, uses and measurement. Reserve Bank of New Zealand, **Discussion Papers**, n 98/9, p. 12-32, 1998.

ROSNICK, D.; WEISBROT, M. Latin American Growth in the 21st Century: the Commodities Boom that wasn't. Washington, D.C. **Center for Economic and Policy Research - CEPR**, 2014. Disponível em: <https://cepr.net/report/latin-american-growth-in-the-21st-century/>. Acesso em: 18 mai 2020.

ROSOIU, A. Monetary policy and factor-augmented VAR Model. **Procedia Economics and Finance**, v. 32, p. 400- 407, 2015. Disponível em: [https://doi.org/10.1016/S2212-5671\(15\)01410-0](https://doi.org/10.1016/S2212-5671(15)01410-0). Acesso em: 9 out. 2019.

SAGHAIAN, S.H.; REED, M. R.; MARCHANT, M.A. Monetary Impacts and Overshooting of Agricultural Prices in an Open Economy. **American Journal of Agricultural Economics**, v. 84, p. 90-103, 2002. Disponível em: <https://www.jstor.org/stable/1245026>. Acesso em: 20 mar. 2020.

SANTOS, C.; CASTELAR, I. Avaliando as medias de núcleo da inflação no brasil. **Revista Economia Aplicada**, São Paulo, v. 20, n.1, p. 35-56, 2016. Disponível em: <https://doi.org/10.11606/1413-8050/ea134823>. Acesso em: 12 mai. 2020.

SCHMIDHUBER, J. QIAO, B. 2020. Comparing Crises: Great Lockdown versus Great Recession. Rome, **FAO**. Disponível em: <https://doi.org/10.4060/ca8833en>. Acesso em: 8 jun. 2021.

SCHWEPPE, F. Evaluation of likelihood functions for Gaussian signals. **IEEE Trans. Inform. Theory**, v. 11, p. 61-70, 1965. Disponível em: <https://doi.org/10.1109/TIT.1965.1053737>. Acesso em: 13 jun. 2020.

SERIGATI, F. C. Fundamentos X Mercados Financeiros. **Agroanalysis**, v. 32, n. 8, p, 15-16, 2012. Disponível em: <file:///C:/Users/Lucia%20Sindeaux/Downloads/admin,+24623-44937-1-CE.pdf>. Acesso em: 12 mai. 2020.

SHAOPING. W. XIAOTAO. S. Codependent Cycles of Chinese Inflation. School of Economics, Huazhong University of Science and Technology. **Social Sciences in China**, v. 35, n. 4, p..31-45, 2014. Disponível em: <http://dx.doi.org/10.1080/02529203.2014.968343>. Acesso em: 23 mai 2019.

SHARMA, N.K.; BICCHAL, M. Measuring core inflation in India: An asymmetric trimmed mean approach. **Cogent Economics e Finance**, v. 3, p. 1-15, 2015. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/23322039.2015.1014252>. Acesso em: 2 jan. 2020.

SILVA FILHO, T. N. T.; FIGUEIREDO, F. M. R. Revisitando as Medidas de Núcleo de Inflação do Banco Central do Brasil. **Trabalho para Discussão**, São Paulo, n. 356, p. 1-30, 2014. Disponível em: <https://www.bcb.gov.br/pec/wps/port/TD356.pdf>. Acesso em: 12 mai. 2020.

SILVA, A. M *et al.* Modelagem da Relação entre a Inflação do Consumidor e a Inflação do PIB. **Carta de Conjuntura**, Rio de Janeiro, n. 35, p.1-17, 2017. Disponível em: <https://www.ipea.gov.br/cartadeconjuntura/index.php/2017/05/30/modelagem-da-relacao-entre-a-inflacao-do-consumidor-e-a-inflacao-do-pib/>. Acesso em: 2 jan. 2019.

SIMONSEN, M. H. A Inflação Brasileira: Lições e Perspectivas. **Revista de Economia Política**, Rio de Janeiro, v.5 n. 4, p. 17 – 32, 1985.

SMITH, J. K. Weighted median inflation: is this core inflation. **Journal of Money, Credit, and Banking**, v.36, p. 253-63, 2004. Disponível em: <https://www.jstor.org/stable/3839019>. Acesso em: 18 mai. 2020

SOARES, A. F et al. Análise da Dinâmica Inflacionária no Brasil e Preços de Commodities: Uma aplicação do modelo de vetores autorregressivos. **Teoria e Evidência Econômica**, Pelotas, v. 22, p. 178-198, 2016. Disponível em: <http://seer.upf.br/index.php/rtee/article/view/6758>. Acesso em: 3 dez. 2019.

SOTO, C. Non-Traded Goods and Monetary Policy Trade-Offs in a Small open Economy. **Working Paper**, n. 214, p. 54-76, 2003.

SOUZA, R. G de. **Três Ensaio Sobre Política Monetária**: Preços de Commodities, Taxa de Câmbio Real e Inflação. Tese de doutorado - Programa de Pós-Graduação em Economia da Indústria e da Tecnologia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2016.

Disponível em:

<https://www.ie.ufrj.br/images/IE/PPGE/teses/2016/Rodrigo%20Gustavo%20de%20Souza.pdf>

. Acesso em: 4 abr. 2020.

SOUZA, W. P. S de Farias. Preços de Alimentos e Dinâmica Inflacionária no Brasil: uma Aplicação do Modelo de Vetores Autorregressivos (VAR). **Revista Economia & Desenvolvimento**, Paraíba, v.14, p.111-125, 2015. Disponível em:

<https://periodicos.ufpb.br/index.php/economia/issue/view/1706>. Acesso em: 3 dez. 2019.

STOCK, J.; WATSON, M. Why has U.S. inflation become harder to forecast? **Journal of money, credit and banking**, v.39, n. 1, p.3-33, 2007.

SUN, W.; DE, KUHELKA. Exchange rate, monetary policy, and the U.S. economy: evidence from a FAVAR model. **Economic inquiry**, v.57, n. 1, p.552-568, 2019. Disponível em: <https://doi.org/10.1111/ecin.12723>. Acesso em: 3 dez. 2020.

TAN, Y.; SHA, W.; PAUDEL, P.K. The Impact of Monetary Policy on Agricultural Price in China: A Factor-Augmented Vector Autoregressive (FAVAR) Approach. Selected Paper Prepared for presentation at the Southern Agricultural Economics **Association Annual Meeting, Mobile**, p.4-7, 2017.

WAGAN Z, A. et al. Assessing the Effect Of Monetary Policy on Agricultural Growth and Food Prices. **Agric. Econ**, n. 64, p. 499–507, 2018. Disponível em:

https://www.agriculturejournals.cz/web/agricecon.htm?type=article&id=295_2017-AGRICECON. Acesso em: 12 mai. 2019.

YOGO, M. Measuring business cycles: A wavelet analysis of economic time series. **Economics letters**, v. 100, n. 2, p. 208-212, 2008.

ZUNIGA, M. International monetary transmission, a factor-augmented vector autoregressive (FAVAR) Approach: The Cases of Mexico and Brazil. **Business and economics journal**, v. 26, p.1–16, 2011.

APÊNDICE

Tabela A.1.1 – Testes de Raiz Unitária Dickey-Fuller Aumentado (ADF) e KPSS

Variáveis	Valores Críticos ADF (τ_c)	
	1ª Diferença	Nível
<i>IGPM</i>	-6,618913 (**)	-4,617248(**)
<i>IPA</i>	-7,581464 (**)	-3,935165 (**)
<i>M2</i>	-5,212180 (**)	-3,199613 (**)
Variáveis	Valores Críticos KPSS (η_c)	
	1ª Diferença	Nível
<i>IGPM</i>	0,045033	0,352106
<i>IPA</i>	0,030208	0,363190
<i>M2</i>	0,160108	0,135742

Fonte: Elaboração própria.

Notas: (**) indica rejeição da hipótese nula ao nível de 5% de significância. Os valores críticos dos testes ADF e KPSS, com constante, são baseados nos trabalhos de MacKinnon (1996) e de Kwiatkowski *et al.* (1992), respectivamente.

Tabela A.2.1 – Teste ADF de Raiz Unitária – Séries em Taxa de Crescimento Anual

Variáveis	Estatística ADF
Arroz (em casca)	-3.725*
Milho (em grão)	-4.618*
Trigo (em grão)	-3.274*
Algodão (em caroço)	-4.918*
Cana-de-açúcar	-4.300*
Fumo (em folha)	-3.128*
Soja (em grão)	-4.486*
Abacaxi	-3.344*
Batata-Inglesa	-3.781*
Feijão (em grão)	-3.618*
Mandioca (Aipim)	-3.274*
Tomate	-4.885*
Laranja	-3.857*
Uva	-4.373*
Banana	-4.485*
Coco-da-Baía	-6.839*
Maçã	-4.476*
Mamão	-4.293*
Café (em grão)	-3.368*
Cacau	-2.968*
Bovinos	-3.813*
Leite <i>in natura</i>	-4.529*
Suínos	-4.281*

Aves	-3.869*
Ovos	-2.961*
<hr/>	
IPCA	-5.718*
Taxa de Câmbio Efetiva	-3.922*
Incerteza Político-Econômica	-4.856*
Taxa Selic Over	-5.475*
IBC	-2.848*
Preço Spot Petróleo (BRENT)	-3.274*
<hr/>	
Fator 1	-4.309*
Fator 2	-3.568*
Fator 3	-3.068*

Fonte: Elaboração própria.

Nota: Foi utilizado o teste de raiz unitária ADF, considerando somente intercepto e até seis defasagens, definido a partir do critério de Schwarz. Valor Crítico a um nível de 5% (-2,88).

Tabela A. 2.2 – Estatística descritiva – Correlação entre os Fatores Comuns

<i>Commodities</i> Agropecuárias	Fator 1	Fator 2	Fator 3
Lavoura Temporária			
Arroz (em casca)	0,639	0,042	0,397
Milho (em grão)	0,707	0,376	-0,071
Trigo (em grão)	0,674	0,201	0,366
Algodão (em caroço)	0,288	0,673	-0,270
Cana-de-açúcar	-0,410	0,163	-0,757
Fumo (em folha)	-0,097	-0,593	0,156
Soja (em grão)	0,726	0,068	0,428
Abacaxi	0,546	0,015	0,409
Batata-Inglesa	0,411	-0,306	0,355
Feijão (em grão)	0,699	0,256	0,254
Mandioca (Aipim)	0,668	0,011	0,524
Tomate	0,153	-0,258	0,417
Lavoura Permanente			
Laranja	0,178	0,556	-0,264
Uva	0,186	-0,209	-0,029
Banana	0,434	0,255	-0,221
Coco-da-Baía	-0,152	0,200	-0,493
Maçã	0,606	0,067	-0,125
Mamão	0,130	-0,595	0,122
Café (em grão)	0,031	0,276	-0,419
Cacau	0,395	-0,170	0,118
Pecuária			
Bovinos	0,545	0,456	0,122
Leite <i>in natura</i>	0,565	0,416	0,086
Suínos	0,565	0,325	0,384
Aves	0,768	0,139	0,456
Ovos	0,661	0,341	0,430

Fonte: Elaboração própria.

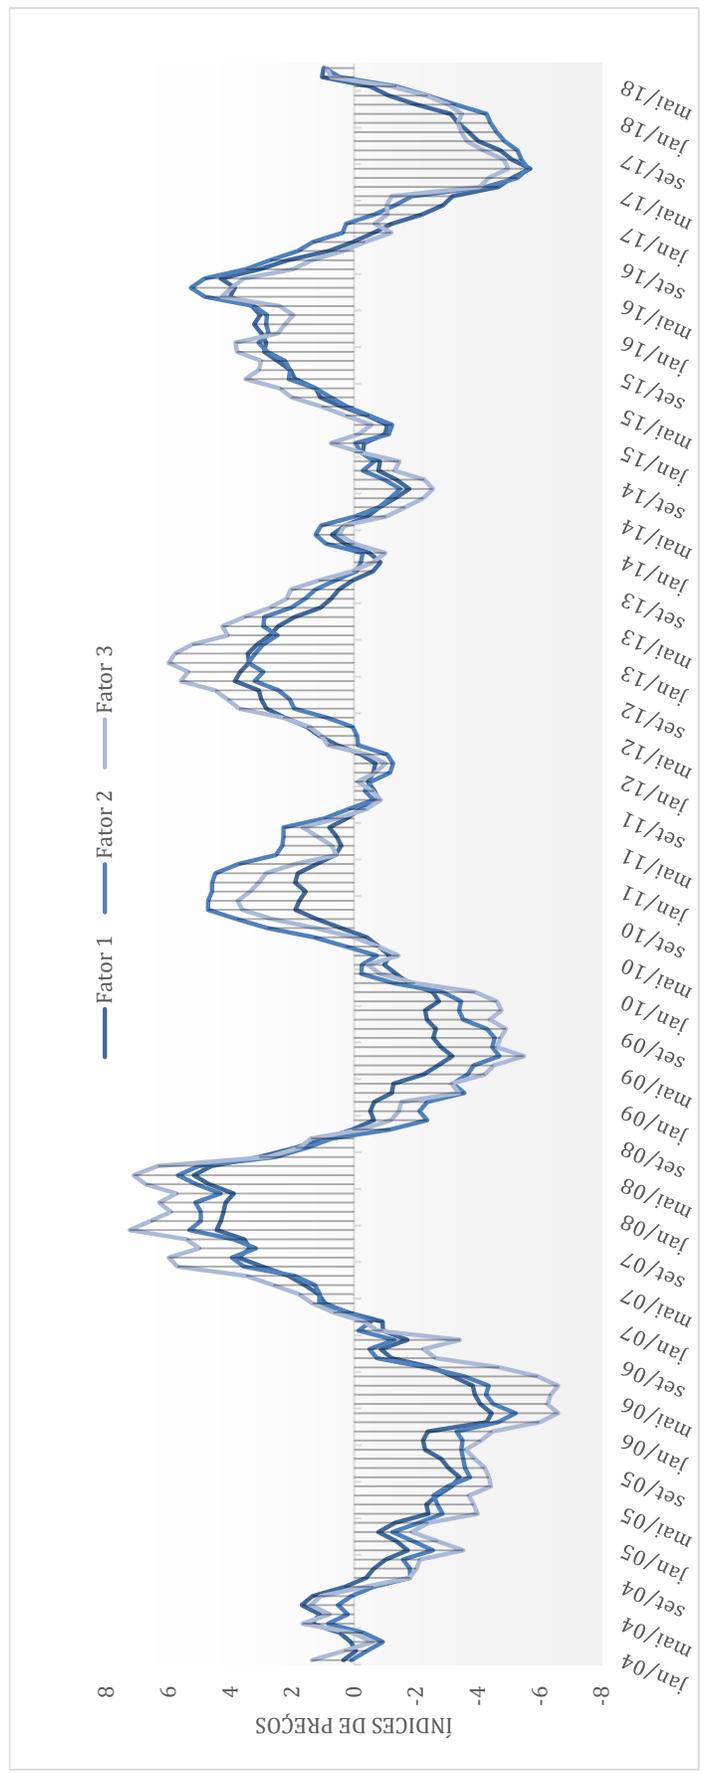
Tabela A.2.3 – Matriz de Covariância e Correlação dos Índices Macroeconômicos e agropecuários

Matriz de covariância de resíduos									
	IPCA	Câmbio	Incerteza	juros	IBC	Brent	Fator 1	Fator 2	Fator 3
IPCA	0,620	0,011	0,002	0,033	0,048	-0,007	0,096	0,026	0,084
Câmbio	0,011	0,107	0,069	0,010	0,001	-0,031	-0,001	0,010	0,025
Incerteza	0,002	0,069	0,463	-0,003	-0,012	-0,030	0,057	0,045	0,081
Juros	0,033	0,010	-0,003	0,130	0,135	-0,020	-0,002	-0,006	-0,009
IBC	0,048	0,001	-0,012	0,135	0,234	-0,007	0,023	-0,016	-0,021
Brent	-0,007	-0,031	-0,030	-0,020	-0,007	0,100	0,032	-0,001	-0,021
Fator1	0,096	-0,001	0,057	-0,002	0,023	0,032	0,294	0,035	0,062
Fator2	0,026	0,010	0,045	-0,006	-0,016	-0,001	0,035	0,117	-0,004
Fator3	0,084	0,025	0,081	-0,009	-0,021	-0,021	0,062	-0,004	0,143

Matriz de correlação de resíduos									
	IPCA	Cambio	Incerteza	juros	IBC	Brent	Fator 1	Fator 2	Fator 3
IPCA	1,000	0,042	0,004	0,118	0,125	-0,027	0,224	0,097	0,283
Câmbio	0,042	1,000	0,309	0,083	0,004	-0,296	-0,004	0,088	0,201
Incerteza	0,004	0,309	1,000	-0,013	-0,036	-0,140	0,155	0,191	0,312
Juros	0,118	0,083	-0,013	1,000	0,775	-0,175	-0,010	-0,052	-0,065
IBC	0,125	0,004	-0,036	0,775	1,000	-0,045	0,087	-0,095	-0,114
Brent	-0,027	-0,296	-0,140	-0,175	-0,045	1,000	0,185	-0,007	-0,171
Fator1	0,224	-0,004	0,155	-0,010	0,087	0,185	1,000	0,186	0,300
Fator2	0,097	0,088	0,191	-0,052	-0,095	-0,007	0,186	1,000	-0,031
Fator3	0,283	0,201	0,312	-0,065	-0,114	-0,171	0,300	-0,031	1,000

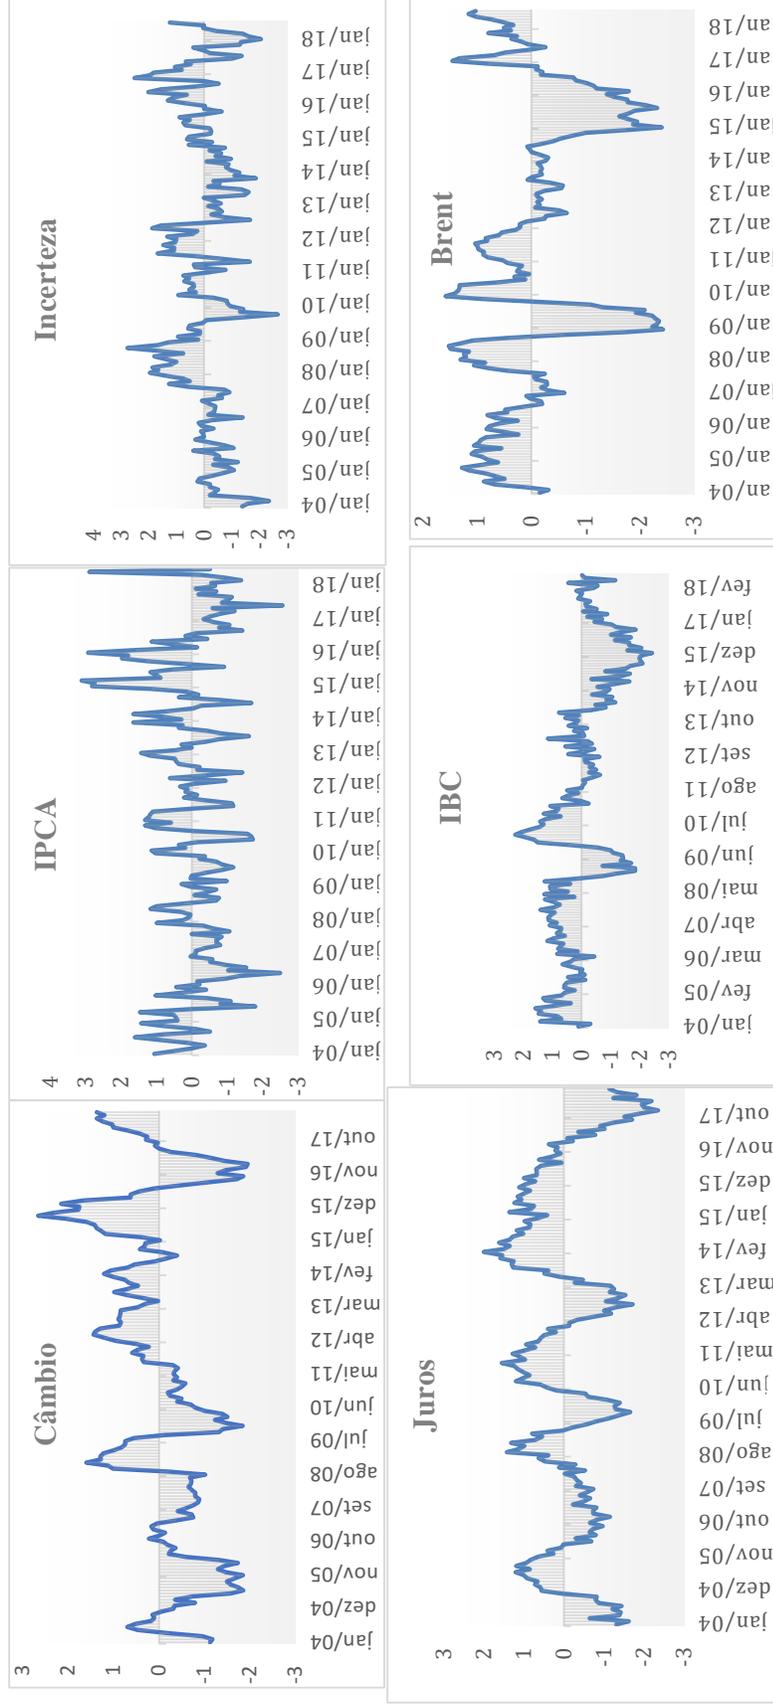
Fonte: Elaboração própria.

Gráfico A.2.1 – Índices dos Fatores Agropecuários utilizados no modelo



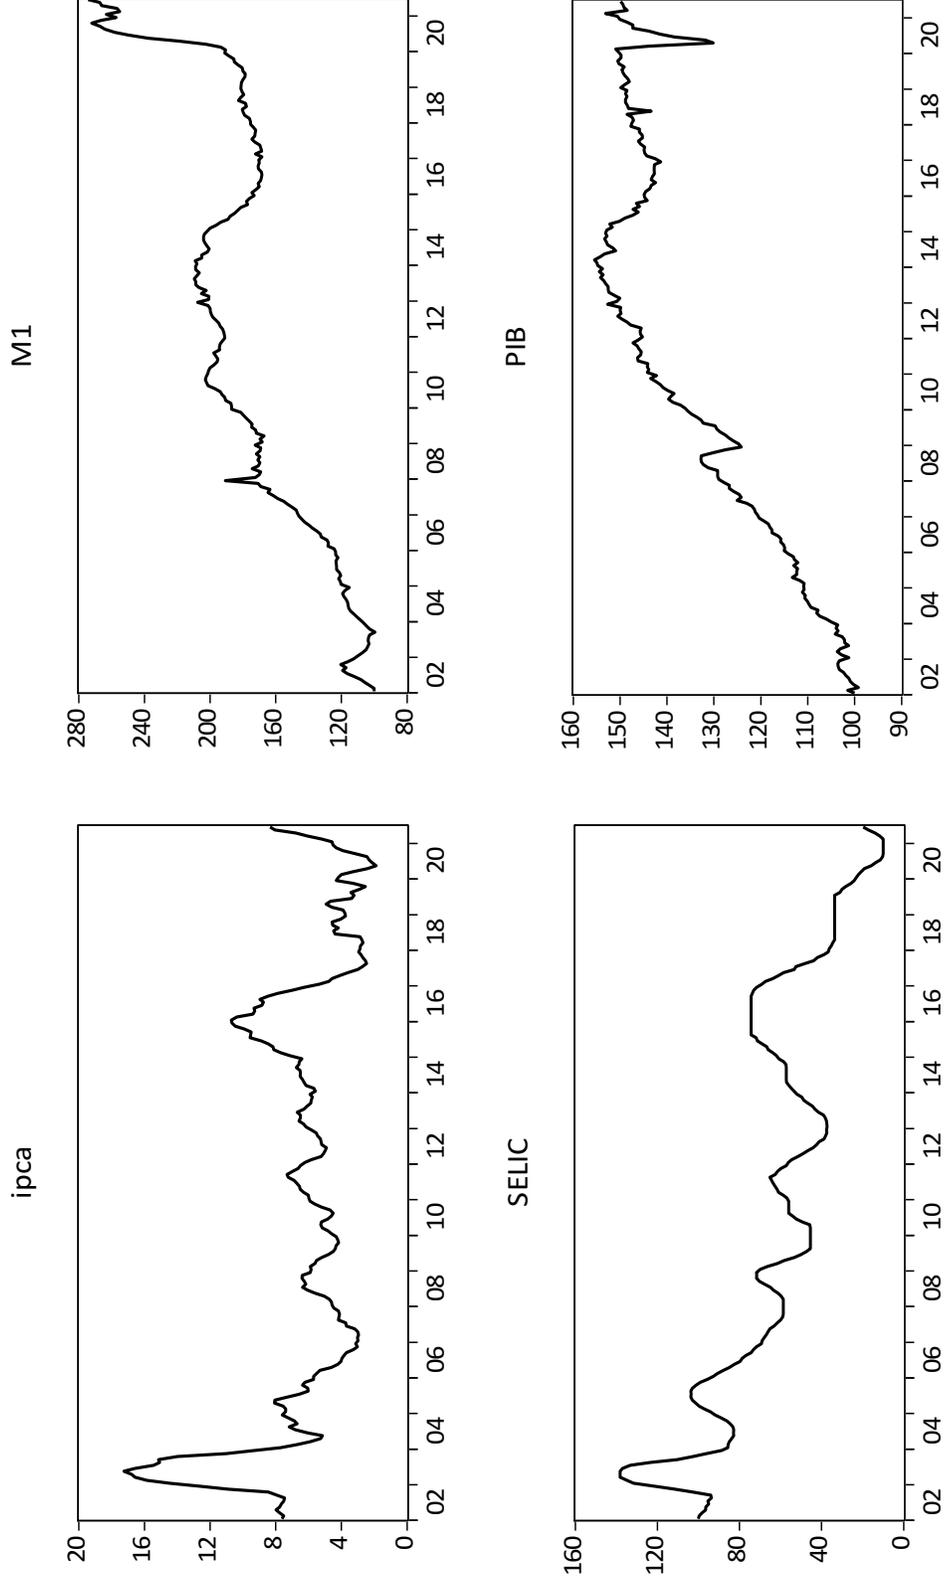
Fonte: Elaboração própria.

Gráfico A.2.2 – Índices das Variáveis Macroeconômicas utilizados no modelo



Fonte: Elaboração própria.

Gráfico A.3.1 – Variáveis utilizadas na Modelagem de Componentes Não Observados



Fonte: Elaboração própria.

Nota: As variáveis PIB mensal em volume e M1 real, bem como a SELIC nominal % a.a. estão transformados em número índice com base em janeiro de 2002, enquanto o IPCA mensal encontra-se em variação percentual acumulada nos últimos 12 meses