



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE ECONOMIA
MONOGRAFIA DE BACHARELADO

Maria Eduarda Martins Coelho

UM COMPARATIVO DE MODELOS UNIVARIADOS E MULTIVARIADOS PARA A
PREVISÃO DA INFLAÇÃO BRASILEIRA

Rio de Janeiro
2022

Maria Eduarda Martins Coelho

UM COMPARATIVO DE MODELOS UNIVARIADOS E MULTIVARIADOS PARA A
PREVISÃO DA INFLAÇÃO BRASILEIRA

Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Ciências Econômicas da Universidade Federal do Rio de Janeiro, como requisito para a obtenção do título de Bacharel de Ciências Econômicas.

Orientadora: Professora Dra. Susan Schommer

Rio de Janeiro

2022

CIP - Catalogação na Publicação

CC672c Coelho, Maria Eduarda Martins
Um comparativo de modelos univariados e
multivariados para a previsão da inflação brasileira
/ Maria Eduarda Martins Coelho. -- Rio de Janeiro,
2022.
39 f.

Orientadora: Susan Schommer.
Trabalho de conclusão de curso (graduação) -
Universidade Federal do Rio de Janeiro, Instituto
de Economia, Bacharel em Ciências Econômicas, 2022.

1. IPCA. 2. Modelos de Inflação. 3. VAR. 4.
ARIMA. 5. Estado de Espaço. I. Schommer, Susan,
orient. II. Título.

Elaborado pelo Sistema de Geração Automática da UFRJ com os dados fornecidos pelo(a) autor(a), sob a responsabilidade de Miguel Romeu Amorim Neto - CRB-7/6283.

MARIA EDUARDA MARTINS COELHO

UM COMPARATIVO DE MODELOS UNIVARIADOS E MULTIVARIADOS PARA A
PREVISÃO DA INFLAÇÃO BRASILEIRA

Trabalho de conclusão de curso apresentado ao
Instituto de Economia da Universidade Federal do
Rio de Janeiro, como requisito para a obtenção do
título de Bacharela em Ciências Econômicas.

Rio de Janeiro, 5/5/2022.

SUSAN SCHOMMER - Presidente
Professora Dra. do Instituto de Economia da UFRJ

VIVIANE PATRIZZI LUPORINI
Professora Dra. do Instituto de Economia da UFRJ

PEDRO JAMES FRIAS HEMSLEY
Professor Dr. do Instituto de Economia da UFRJ

AGRADECIMENTOS

Agradeço aos meus pais, Paula Coelho e Carlos Eduardo Coelho, e ao meu irmão, Felipe Coelho, a quem dedico esse trabalho, pelo apoio, zelo e carinho ao longo de todos os anos da minha vida, sem o qual não teria sido possível chegar até aqui. Ao Frederico Coelho, a quem devo a motivação pela busca à excelência, e por sempre estar ao meu lado ao longo de nossa trajetória juntos.

Agradeço também aos amigos que fiz durante os anos de Escola Parque e na Universidade, pelo suporte e companheirismo desde a adolescência. Obrigada Beatriz Bessa, Giullia Calçada, Thiago Richter, Dafne Godoy, Enzo Mansano, Giullia Pontual, Guilherme Rocha, João Pedro Peres, João Zandoná, Júlia Crivellari, Maria Proença, Mariana Regazzi, Pamella Rothstein, Pedro Cavalcante, Luísa Barbeito, Marina Totis e Rodrigo Galvão.

Adicionalmente, deixo minha gratidão ao Instituto de Economia e a todos os funcionários, Professores e colegas que ao longo do tempo me ensinaram e estimularam meu desenvolvimento como economista.

RESUMO

A previsão de inflação é de extrema importância para as decisões de um Banco Central como o brasileiro, que segue o regime de metas de inflação. Existem múltiplas formas de prever esta variável; neste trabalho, quatro delas serão comparadas: uma multivariada e três univariadas. Para a primeira, foi utilizado um Vetor Autorregressivo (VAR) baseado no modelo teórico da Curva de Phillips. Os modelos univariados consideram os métodos ARIMA (*Autoregressive Integrated Moving Average*), ETS (*Exponential Smoothing*) e BSM (*Basic Structural Model*). Para analisar a performance da previsão da inflação do Índice de Preços ao Consumidor Amplo (IPCA), foram utilizados dois períodos distintos - antes e após a pandemia Covid-19. Ao final, foi possível verificar que os modelos univariados tiveram melhor desempenho nas estimativas.

Palavras-chave: IPCA, Inflação, VAR, ARIMA, Basic Structural Model, Exponential Smoothing Model.

ABSTRACT

Predicting inflation is extremely important for Central Bank's decision-making process, especially the ones that follow an inflation targeting regime, such as the Brazilian Central Bank. There are multiple ways to forecast this variable, and in this essay four different methods will be compared - a multivariate one and three univariate ones. For the first one was used a Vector Autoregression (VAR) approach based on the theoretical Phillips Curve model. The univariate models considered the methods ARIMA (Autoregressive Integrated Moving Average), ETS (Exponential Smoothing) and BSM (Basic Structural Model). To analyze their performance in forecasting the inflation of the Ample Consumer Price Index (IPCA), two periods were used – before and after the Covid-19 pandemic. At the end, the univariate models performed better at the estimates.

Keywords: IPCA, Inflation, VAR, ARIMA, Basic Structural Model, Exponential Smoothing Model.

LISTA DE TABELAS

Tabela	1	-	Testes de Raiz Unitária	-	Dick-Fuller	Aumentado	
.....24							
Tabela	2	-	Resultados		das	estimações	
ARIMA.....25							
Tabela	3	-	Raiz do Erro		Quadrático	Médio	
(ARIMA).....27							
Tabela	4	-	Comparativo		VAR	2020	
.....29							
Tabela	5	-	Comparativo		VAR	2019	
.....30							
Tabela	6	-	Raiz do Erro		Quadrático	Médio (BSM e	
ETS).....34							
Tabela	7	-	Comparativo		Raiz do Erro	Quadrático	Médio
.....36							
Tabela	8	-	Modelos		versus	Focus	
.....37							

LISTA DE GRÁFICOS

Gráfico 1	-	Inflação	<i>versus</i>	Desemprego	nos	Estados Unidos.....	13
Gráfico 2	-	Variação da inflação	<i>versus</i>	Desemprego	nos	Estados Unidos	14
Gráficos 3 e 4	-					IPCA	19
Gráfico 5	-	Câmbio Nominal	em	Dólares	por	Real.....	19
Gráfico 6	-	Expectativa de	Inflação	12	Meses	à Frente.....	20
Gráfico 7	-			Incerteza		da Economia.....	21
Gráfico 8	-			Hiato	do	Produto	22
Gráfico 9	-			Taxa	de	Desemprego Composta.....	23
Gráfico 10	-	Variáveis usadas	no	cálculo	do	hiato do produto.....	23
Gráficos 11 e 12	-	Autocorrelação	Parcial	e	Autocorrelação	do IPCA.....	25
Gráficos 13 e 14	-	Projeção	ARIMA	IV	e	V 2020.....	26

Gráficos 15 e 16	-	Projeção	ARIMA	IV	e	V
2019.....						27
Gráficos 17	-	Critérios		de		Informação:
VAR.....						28
Gráficos 18 e 19	-	VAR(3)		e		VAR(1)
2020.....						29
Gráficos 20 e 21	-	VAR(3)		e		VAR(1)
2019.....						30
Gráfico 22	-					Decomposição
BSM.....						31
Gráfico 23	-	Projeção		Modelo		BSM
2020.....						32
Gráfico 24	-	Projeção		Modelo		BSM
2019.....						32
Gráfico 25	-	Projeção		Modelo		ETS
2020.....						33
Gráfico 26	-	Projeção		Modelo		ETS
2019.....						34
Gráfico 27	-	Focus	Mediana	das	Expectativas	de
Inflação.....						35
Gráfico 28	-	Índice	Mundial	de	Commodities	do
FMI.....						36

SUMÁRIO

1 INTRODUÇÃO	11
2 REFERENCIAL TEÓRICO	12
3 METODOLOGIA	15
4 ESTIMAÇÕES E RESULTADOS	18
4.1 Análise preliminar das variáveis	18
4.2 Resultados das estimações	24
4.3 Interpretação e análise	34
5 CONCLUSÃO	38
6 REFERÊNCIAS	39

1 INTRODUÇÃO

A partir da adoção do regime de Metas de Inflação pelo Banco Central do Brasil, em 1999, a previsão da inflação tornou-se uma ferramenta muito importante para as decisões de política monetária no país. Guiado pelo objetivo de fazer com que a inflação efetiva seja compatível com o alvo previamente determinado, os *policymakers* decidem sobre o nível da taxa de juros. A transmissão da política monetária funciona por quatro canais principais: crédito, expectativas, taxa de câmbio e preços de ativos (Banco Central do Brasil, Relatório de Inflação de junho de 1999); através destes, aumentos de taxas de juros desaceleram a atividade econômica o que, por sua vez, deveria levar a uma diminuição da inflação.

É preciso notar, contudo, que apenas um dos mecanismos de difusão citados acima reage de maneira imediata a um aumento da taxa básica de juros da economia (Selic): a taxa de câmbio. Dado que a moeda é negociada internacionalmente em mercados financeiros, a reprecificação é praticamente instantânea após movimentos da taxa de juros. Por outro lado, o crédito, preços de ativos e expectativas demoram a reagir a mudanças, devido a contratos duradouros, ao tempo de realocação de capital das famílias, entre outros. Dito isso, os efeitos das decisões do Banco Central levam algum tempo até atingirem a economia real, e por isso a previsão da inflação em um horizonte de curto e médio prazo se faz imprescindível: para decidir sobre a taxa de juros hoje, os *policymakers* devem ter informação sobre a inflação à frente.

Para isso, os bancos centrais e outros agentes econômicos que desejam antecipar seus movimentos lançam mão de modelos econométricos, que podem ter metodologias - e resultados - múltiplos. O objetivo deste trabalho é precisamente a análise e comparação dos diferentes resultados de algumas das abordagens possíveis para prever a inflação. Para isso, serão abordados quatro modelos diferentes: três univariados e um multivariado.

Àqueles normalmente possuem uma boa *performance* de curto prazo, uma vez que a inflação possui um caráter bastante inercial no Brasil, uma economia altamente indexada por mecanismos formais e não formais. Contudo, este tipo de abordagem habitualmente não produz resultados tão satisfatórios em horizontes mais longos; como só leva em conta a dinâmica da própria inflação, falha em captar mudanças estruturais na economia que afetam diretamente o nível e variação de preços (o nível de emprego, a evolução das expectativas de inflação, a inflação externa e o câmbio, por exemplo). Modelos multivariados, por outro lado, são mais rebuscados e permitem a inserção de outras variáveis, e por isso são utilizados por grande parte dos bancos centrais ao redor do mundo (Banco da Inglaterra, Banco do Canadá,

Banco de Reserva da África do Sul, por exemplo). A escolha das variáveis explicativas, no entanto, não é trivial. Por isso, para embasá-la, a Curva de Phillips foi utilizada como referencial teórico. Particularmente, a especificação elaborada pelo Banco Central do Brasil (BCB) em seu Modelo Agregado de Pequeno-Porte do Relatório de Inflação de junho de 2017, foi utilizada como inspiração.

Este trabalho será apresentado em quatro partes: primeiro, será apresentado o referencial teórico empregado para a estruturação do trabalho. Em seguida, os métodos quantitativos serão introduzidos, assim como os critérios para avaliar suas *performances* e características. Posteriormente, as variáveis serão examinadas individualmente, e os resultados dos diferentes modelos testados serão analisados. Por último, as previsões para o IPCA serão comparadas.

2 REFERENCIAL TEÓRICO

Em sua versão original, a Curva de Phillips foi pensada inicialmente por W. Phillips (1958) e elaborada por Paul Samuelson e Robert Solow e propunha a existência de uma relação inversa entre desemprego e inflação. Essa conclusão foi derivada de observações no Reino Unido entre 1861 e 1957 e nos Estados Unidos entre 1900 e 1960, que mostravam com clareza que períodos de taxa de inflação elevada eram acompanhados de baixo desemprego, enquanto períodos de inflação baixa, ou mesmo negativa, eram acompanhados de uma alta taxa de desemprego. A descoberta desta relação foi de extrema importância para a política macroeconômica do período, uma vez que implicava que países poderiam escolher combinações diferentes de taxa de inflação e desemprego ao longo da curva (BLANCHARD, 2013, p.194).

Nessa versão, a curva é definida pela equação a seguir: π_t representa a inflação no período presente (t), π_t^e a inflação futura esperada no período t e u_t é a taxa de desemprego no mesmo período. As variáveis m e z refletem, respectivamente, a margem das empresas e todos os outros aspectos que influenciam o desemprego, como arranjos legais, seguro-desemprego, rigidez do mercado de trabalho, poder de barganha dos trabalhadores etc.


$$\pi_t = \pi_t^e + (m + z) - \alpha u_t$$

Da apresentação formal do problema, podemos retirar algumas relações importantes. A primeira delas é que um aumento na taxa de inflação esperada leva a um aumento da taxa de inflação presente. Isso acontece porque os fixadores de salários consideram a inflação

futura na determinação de salários nominais. Portanto, esperando uma taxa de inflação mais alta, fixam salários mais altos, o que eleva o nível de preços. A segunda é que uma diminuição da taxa de desemprego em t aumenta a inflação corrente. O mecanismo de transmissão deste efeito é novamente os salários, já que uma oferta de trabalho mais comprimida leva à fixação de salários nominais mais elevados para atrair trabalhadores, o que resulta em um nível de preços mais elevado.

Quando publicada, era fácil verificar na realidade material as conclusões expressas acima, e a economia parecia de fato seguir os mecanismos propostos pela Curva de Phillips; conforme retrata o gráfico abaixo (Gráfico 1), que relaciona a taxa de inflação ao consumidor e taxa de desemprego nos Estados Unidos entre 1950-1969. Contudo, as previsões feitas por Friedman em 1968 se provaram corretas e a equação acima parou de valer ao longo dos anos 1970, quando uma grande parte dos países experienciou uma combinação de inflação e desemprego altíssimos.

Gráfico 1 - Inflação versus Desemprego nos Estados Unidos



Fonte: Elaboração própria a partir de dados do *Bureau of Labor Statistics*.

Em “*The Role of Monetary Policy*”, publicado em 1968, Milton Friedman criticou a Curva de Phillips original apontando que “implicitamente, Phillips escreveu seu artigo para um mundo em que todos previam que os preços nominais seriam estáveis e em que essa previsão permaneceria sólida e imutável independentemente do que acontecesse com os preços e os salários reais” (p.8). Por isso, “expressando a conclusão de modo diferente,

sempre há um *trade-off* temporário entre inflação e desemprego; não existe um *trade-off* permanente. O *trade-off* temporário vem não da inflação em si, mas de uma taxa de inflação crescente” (FRIEDMAN, 1968, p.11).

O desaparecimento da curva de Phillips original, portanto, se deu porque os agentes mudaram a maneira que formavam suas expectativas em relação à inflação. Com a maior persistência do comportamento inflacionário, as entidades começaram a incorporar em suas expectativas, além de um componente fixo, um componente autorregressivo, de maior peso. Matematicamente:

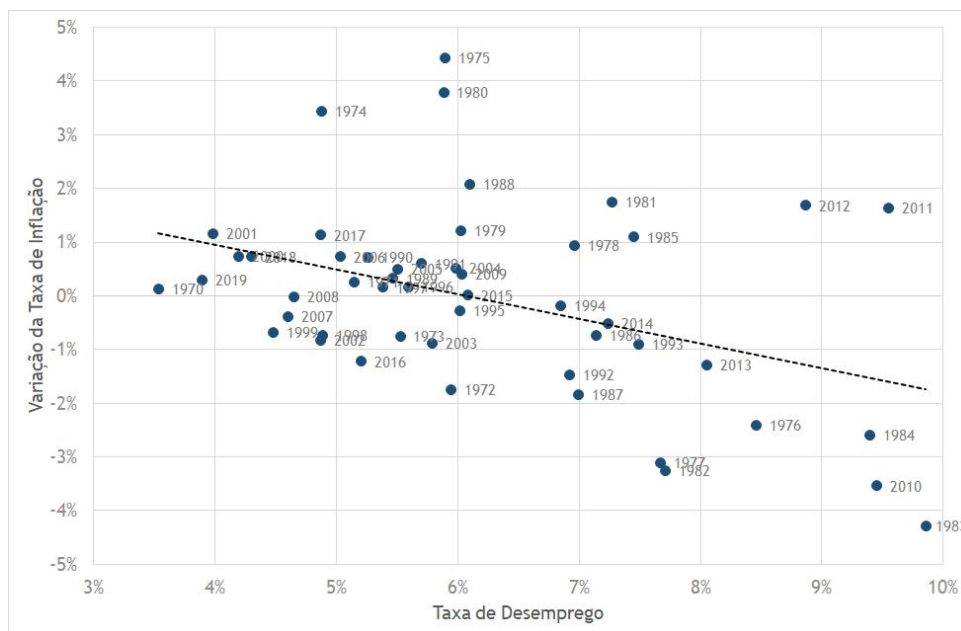
$$\pi_t^e = (1 - \theta)\pi + \theta \pi_{t-1}$$

Substituindo esta equação na curva de Phillips original, considerando $\theta=1$, e derivando temos:

$$\pi_t - \pi_{t-1} = (m + z) - \alpha u_t$$

Portanto, o *trade-off* passou a ser entre a taxa de desemprego e a variação da taxa de inflação. Dessa forma, um aumento na taxa de desemprego causa desaceleração da taxa de inflação, enquanto uma queda do desemprego causa a sua aceleração (Gráfico 2). Apesar desta relação negativa existir, ela não é estrita, como apontado por Blanchard (2013, p. 176).

Gráfico 2 - Variação da inflação *versus* Desemprego nos Estados Unidos entre 1970-2019



Fonte: Elaboração própria a partir de dados do *Bureau of Labor Statistics*.

É preciso ressaltar que os dados apresentados acima (Gráfico 2) como evidência são referentes à economia americana, de modo que as conclusões aferidas não são completamente

transferíveis para o Brasil, e, portanto, para o exercício que será feito neste trabalho. Isso porque a economia brasileira possui características completamente diferentes da americana.

Em primeiro lugar, as expectativas de inflação são formadas de maneira distinta, em especial devido à herança da hiperinflação e um Banco Central ainda jovem quando se trata do sistema de metas de inflação. Adicionalmente, o comportamento esperado do câmbio tem grande impacto sobre a formação de expectativas, uma vez que preços proeminentes como alimentos e gasolina são ligados intimamente ao mercado internacional. Por último, o mercado de trabalho é marcado por uma rigidez maior do que o dos Estados Unidos, além de possuir um alto grau de informalidade. Para garantir que a curva adaptada fosse compatível com as idiossincrasias brasileiras, o modelo multivariado elaborado teve como base um dos modelos utilizados pelo Banco Central do Brasil, que será explicado com mais profundidade na seção de Metodologia.

3 METODOLOGIA

Com o objetivo de comparar algumas das múltiplas formas de projetar a inflação no Brasil, foram elaborados quatro tipos de modelos diferentes: três univariados e um multivariado. Para o último, a escolha das variáveis foi inspirada no modelo agregado semiestrutural de pequeno porte do Banco Central (“Modelo agregado de pequeno porte”. Relatório de Inflação de junho de 2017). O modelo é especificado a partir de uma Curva de Phillips, em que a inflação de preços livres é explicada pela expectativa de inflação, o hiato do produto, uma medida de inflação externa e uma variável de controle. As principais mudanças feitas neste trabalho foram a inclusão de uma variável de incerteza, que está presente no modelo do BC através da especificação do hiato, e a substituição da medida de inflação externa pelo câmbio.

O primeiro e mais simples método univariado utilizado foi o ARIMA, que consiste em um processo autorregressivo integrado de médias móveis. Neste modelo, a variável de interesse - nesse caso, o IPCA - depende de suas próprias defasagens e das defasagens de seus erros, uma vez que podem persistir por mais de um período. Se a série em nível for integrada de ordem maior ou igual a um, deve ser diferenciada até que apresente estacionariedade. Para definir qual o número de defasagens usar, aplicamos a metodologia Box-Jenkins para identificar as possíveis ordens do modelo e as estatísticas de critério de informação para elencá-las. A equação geral de um ARIMA (p,0,q), que busca explicar uma variável y estacionária (I(0)) é:

$$y_t = c + \sum_{i=1}^p \phi^i y_{t-1} + \sum_{j=0}^q \theta^j \epsilon_{t-j}$$

A segunda e terceira técnicas univariadas utilizadas foram modelos de Estado de Espaço, comumente utilizados para prever e suavizar séries temporais. Os modelos são formados por dois componentes: os dados observados - nesse caso, a série do IPCA - e os dados não observados que constituem essa série - tendência, sazonalidade e erro. Desta maneira, temos 2 equações principais: a equação de observação e a equação de estado. A última descreve a dinâmica das variáveis de estado, não observadas, enquanto a primeira relaciona as variáveis observadas ao vetor de variáveis de estado. Matematicamente temos:

- Equação observada: $y_t = f'x_t + \epsilon_t$
- Equação de estado: $x_t = Gx_{t-1} + \omega_t$

Em que f é um vetor de extensão p que relaciona y_t e x_t , x_t é o vetor de estado também de extensão p , e G é uma matriz $p \times p$.

Dentro desta estrutura de modelos, foi empregada a suavização exponencial simples e o modelo estrutural básico. O primeiro tem suas previsões derivadas de médias ponderadas de previsões passadas, que perdem peso à medida em que se recua mais no tempo, ou seja, quanto mais recente a observação, maior será seu peso. A equação observada que descreve a técnica relaciona a variável dependente a um vetor de estado formado por um componente de nível não observado. Matematicamente, temos:

- Equação de estimação:

$$y_{T+hvt} = \sum_{j=1}^t \alpha(1-\alpha)^{t-j} y_j + (1-\alpha)^t l_0; (0 \leq \alpha \leq 1)$$

- Equação observada: $y_t = l_{t-1} + \epsilon_t$
- Equação de estado: $l_t = l_{t-1} + \alpha \epsilon_t$

O modelo estrutural básico apresenta um vetor de estado decomposto em mais variáveis: nível, tendência e sazonalidade, que variam ao longo do tempo. Portanto, as equações que o compõem:

- Equação observada: $y_t = l_{t-1} + s_{j,t} + \epsilon_t$
- Equações de estado:

- Nível: $l_t = l_{t-1} + b_{t-1} + \varepsilon_t$
- Tendência: $b_t = b_{t-1} + \zeta_t$
- Sazonalidade: $s_{j,t} = s_{j-1,t-2} + \epsilon_t$

Por último, o modelo multivariado escolhido foi o de vetores autorregressivos (VAR), que descreve um conjunto de equações simultâneas que guardam as dinâmicas de interação entre as variáveis e permite avaliar o impacto de choques sobre cada uma delas individualmente. Neste tipo de sistema, as variáveis são descritas como funções de suas próprias defasagens, das defasagens das demais variáveis endógenas e de variáveis exógenas. Pode-se generalizar a forma estrutural de um VAR de ordem p , composto por um vetor de variáveis endógenas X_t que se relacionam por meio de uma matriz A da seguinte forma, onde B é um vetor de coeficientes:

$$AX_t = B_0 + \sum_{i=1}^p B_i X_{t-i} + B \varepsilon_t$$

Neste caso, assim como no modelo ARIMA, é preciso definir a ordem do modelo, isto é, o seu número de defasagens; para isso, aplicamos novamente os critérios de informação para elencar as possibilidades. Por fim, é preciso testar a causalidade de Granger entre as variáveis endógenas do VAR, já que este teste tem como objetivo fundamental julgar se um escalar x ajuda a prever o escalar z , por exemplo. Apesar do nome, o teste tem uma interpretação de previsão, e não de causalidade. Para esta última, lançamos mão da teoria econômica.

Além disso, é importante notar que antes de aplicarmos o modelo VAR, é necessário avaliar a estacionariedade das séries em questão. Caso todas sejam não-estacionárias é preciso realizar um teste para verificar a presença de cointegração; esse fenômeno acontece quando uma combinação linear de séries não estacionárias é estacionária. Neste caso, não seria adequado usar o VAR, e deveríamos aplicar o modelo de Vetor de Correção de Erros para a estimação multivariada.

Com o interesse de comparar a *performance* dos modelos elaborados, foram testados diferentes horizontes de previsão e feitas avaliações para garantir a boa especificação dos modelos - testes de autocorrelação e heterocedasticidade. Em seguida, foram contrastados os resultados e as raízes dos erros quadráticos médios de cada um deles, que serão apresentados

e discutidos na próxima seção. A raiz do erro quadrático médio é definida pela fórmula abaixo, onde \hat{y} denota a estimativa para um parâmetro y , para n observações.

$$\sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$


4 ESTIMAÇÃO E RESULTADOS

4.1 Análise preliminar das variáveis

4.1.1 Variáveis previamente estabelecidas

Para que os modelos fossem comparáveis, todas as variáveis foram transformadas em trimestrais utilizando o dado do último mês do período, já que uma das variáveis utilizadas foi o PIB, que só está disponível trimestralmente.

Gráficos 3 e 4 - IPCA



Fonte: IBGE.

O Gráfico 3, à esquerda, mostra a série original do IPCA em índice, e é possível identificar uma tendência crescente ao longo de todo o período, bem como a presença de um potencial fator de sazonalidade. Ambas as características indicam uma alta probabilidade de que a série não seja estacionária, uma vez que não há reversão à média. Utilizando o teste aumentado Dick-Fuller nos dados do Gráfico 3, a intuição foi confirmada.

Dito isso, a variável foi diferenciada uma vez, obtendo a série do Gráfico 4 (à direita) que parece possuir estacionariedade; realizando o mesmo teste, atestamos esta impressão inicial. Os resultados serão apresentados mais à frente.

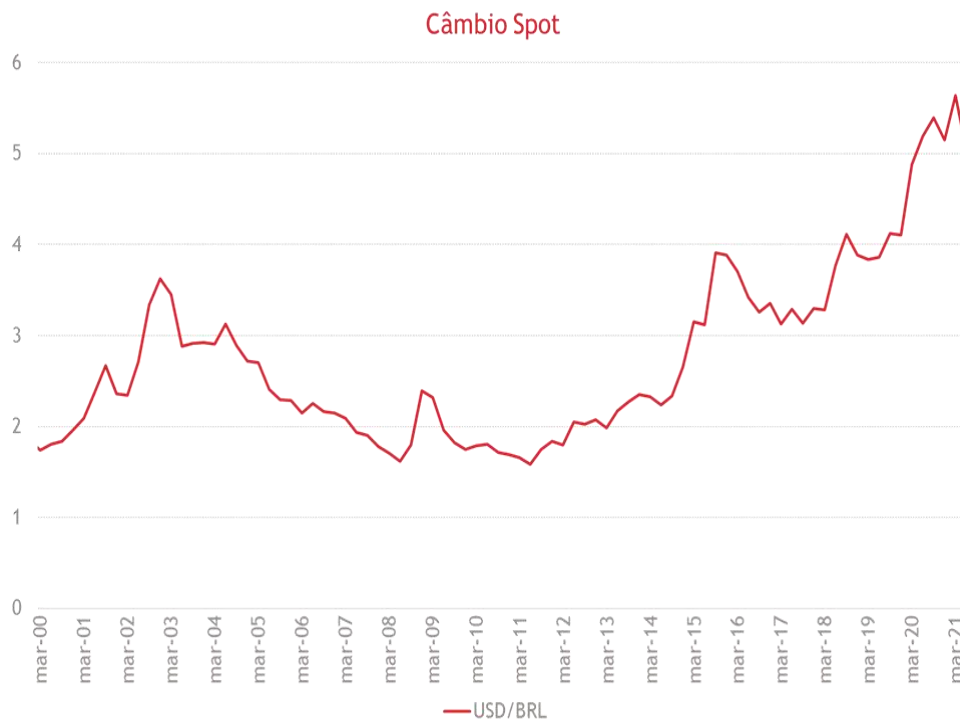



Gráfico 5 - Câmbio Nominal em Dólares por Real

Fonte: Banco Central do Brasil.

No gráfico acima (Gráfico 5), que mostra o câmbio brasileiro em relação ao dólar, estão presentes algumas tendências, ainda que a despeito das variações frequentes da série. No período do primeiro trimestre de 2000 até o fim de 2002, ocorreu um movimento de depreciação do real, assim como durante 2011 e 2015, e posteriormente, a partir de 2018. O intervalo de 2004 até o imediato pré-Grande Recessão foi o único marcado por uma tendência de apreciação da moeda. Lançando mão novamente do teste aumentado Dick Fuller, verifica-se que a série não é estacionária em nível, porém, é em primeira diferença.

Gráfico 6 - Expectativa de Inflação 12 Meses à Frente



Fonte: Banco Central do Brasil.

O Gráfico 6 mostra a expectativa média de inflação, 12 meses à frente, das instituições de mercado financeiro consultadas pelo Banco Central do Brasil, divulgada no relatório semanal do Focus. São identificadas algumas elevações pontuais marcadas por momentos de incerteza por parte dos agentes de mercado, como o início do mandato do Presidente Lula e a crise de 2008, além de um intervalo de desancoragem ao longo de 2015, durante o governo da Presidente Dilma Rousseff. A impressão inicial posta pela análise visual sugere estacionariedade, o que é confirmado pelo mesmo teste utilizado anteriormente, o que será demonstrado à frente.



Gráfico 7 - Incerteza da Economia

Fonte: FGV.

Analisando o Indicador de Incerteza da Economia elaborado pela Fundação Getúlio Vargas, quatro picos chamam a atenção. Os três primeiros coincidem com os intervalos destacados na avaliação das expectativas de inflação; nesta variável, entretanto, estes se apresentam de forma mais pronunciada e extensa, em especial entre 2008-2009 e 2014-2015. Já o quarto movimento, iniciado em 2020, ilustra as consequências do espalhamento do Covid-19 no mundo. Esta incerteza se refletiu nas expectativas de inflação de maneira reversa, causando uma pequena baixa no imediato início da pandemia. Isso porque, à princípio, acreditava-se que o impacto das medidas de restrição à mobilidade seria primordialmente deflacionário, devido a diminuição forçada do consumo. Avaliando a série com o teste aumentado Dick Fuller, atesta-se que esta é estacionária em nível.

4.1.2 Hiato do produto

Gráfico 8 - Hiato do Produto



Fonte: Elaborado pela autora.

Com o objetivo de medir o hiato do produto de forma mais completa, foi elaborada a série apresentada acima (Gráfico 8), utilizando a taxa de desemprego, a utilização de capacidade da indústria medida pela Fundação Getúlio Vargas (NUCI) e produto interno bruto a preços constantes. A primeira, em particular, mensurada pelo IBGE na PNAD, possui um histórico bastante limitado; portanto, para compor uma série mais longa, foram aplicadas como *proxy* a descontinuada Pesquisa Mensal de Emprego até 2012 e a taxa de desemprego na região metropolitana de São Paulo (RMSP) divulgada pelo Seade até 2002. As séries foram transformadas¹ a fim de garantir que a variação dos dados se preservasse sem quebras abruptas ao longo da série construída.

¹ Para garantir que as variáveis fossem compatíveis antes de serem unidas para construir uma única série longa, a PME e a taxa de desemprego da RMSP foram normalizadas de forma a terem média zero e variância 1, e depois transformadas para terem a mesma variância e média histórica da PNAD.





Gráfico 9 - Taxa de Desemprego Composta

Fonte: FGV, IBGE, Seade. Elaborado pela autora.

Em seguida, empregou-se o filtro HP para extrair a tendência do PIB e transformou-se² as outras duas séries - taxa de desemprego e NUCI - obtendo o resultado do gráfico abaixo (Gráfico 10).

Gráfico 10 - Variáveis usadas no cálculo do hiato do produto



Fonte: Elaborado pela autora.

² Tanto a NUCI quanto a taxa de desemprego foram transformadas de forma a preservarem sua variância original e possuem média igual a da série de PIB após passar pelo filtro HP.

Por fim, para congregar a informação de variação do hiato contida em cada uma das 3 séries, foi aplicada a técnica estatística de análise de componentes principais. Esta permite transformar diferentes variáveis em um conjunto de componentes principais, que são uma combinação linear das variáveis anteriores e que buscam preservar o máximo de informação sobre a variação total presente dos dados. O resultado da estimação apresenta um primeiro componente principal que explica 62,76% das variações das variáveis, e por isso, foi selecionado como o único a ser utilizado nos modelos. Observando o hiato do produto obtido, são percebidas muitas variações e uma quebra estrutural a partir do fim de 2014. Fazendo o teste Dick-Fuller (Tabela 1), é possível concluir que a variável é estacionária em nível.

Tabela 1 - Testes de Raiz Unitária - Dick-Fuller Aumentado

Variável	P-Valor	
	Variável em nível	Variável em 1ª diferença
IPCA	0.96	> 0.01
Câmbio	0.9	> 0.01
Expectativa de Inflação	> 0.01	> 0.01
Incerteza	0.02	> 0.01
Hiato do Produto	0.027	> 0.01

Fonte: Elaborado pela autora.

Ao fim desta análise, foi possível eliminar a possibilidade de aplicação do modelo de Vetor de Correção de Erros (VECM). Como citado anteriormente, este modelo é usado em casos em que a combinação linear de variáveis não estacionárias é estacionária, fenômeno chamado cointegração. Uma vez que três das cinco séries vistas já são estacionárias em nível, podemos lançar mão do método VAR para estimar o modelo multivariado.


4.2 Resultado das Estimações

4.2.1 Modelo ARIMA

Inicialmente, a exploração das estimativas se deu pelo método ARIMA - conforme detalhado na seção de Metodologia - utilizando a série do IPCA em primeira diferença, uma vez que esta não é estacionária em nível, e sim I(1). Diferentes variações do modelo foram testadas, empregando diversas combinações de defasagens para o processo autorregressivo e o de médias móveis. A seleção dos *lags* foi feita com base nos testes de autocorrelação e

autocorrelação parcial, que conforme os gráficos abaixo (Gráficos 11 e 12), sugeriram 1 ou 3 defasagens para a dinâmica AR(p), e 1 ou 2 defasagens para a dinâmica MA(q).

Gráficos 11 e 12 - Autocorrelação parcial e autocorrelação do IPCA



Fonte: Elaborado pela autora.

Entre esses modelos, foram escolhidos os que apresentaram melhor *performance* em termos de erro quadrático médio e critério de informação (AIC e BIC). Posteriormente, foram aplicados os testes de especificação para garantir a robustez das estimativas. Na Tabela 2 abaixo, os resultados foram expostos conjuntamente com a raiz dos erros quadráticos médios calculados dentro da amostra de treinamento, que consiste do período entre março de 1998 e junho de 2020.

Tabela 2 - Resultado das Estimções ARIMA

Tabela 2 - Resultado das Estimções ARIMA (p,d,q)					
Modelos	I	II	III	IV	V
p	1	3	1	3	2
d	1	1	1	1	1
q	1	1	0	2	2
Critérios de Informação					
AIC	374,2	358,4	384,1	355,5	357,3
BIC	381,7	370,9	389,1	370,4	369,7
Testes de Especificação					
Ljung-Box	0,007322	0,1096	0,00002	0,2909	0,1404
Erro					
RMSE	1,887	1,683	2,023	1,635	1,672

Fonte: Elaborado pela autora.

Todos os modelos apresentaram p-valores maiores que 5% no teste Breusch Pagan, o que significa que não foi possível rejeitar a hipótese nula de que os erros são homocedásticos.

Já no teste Ljung-Box, apresentado na tabela acima (Tabela 2) apenas dois modelos apresentaram p-valores pequenos o suficiente para rejeitar a hipótese de ausência de autocorrelação dos resíduos. Portanto, podemos concluir que há evidências de que os ARIMAs II, IV e V são bem especificados. Considerando os critérios de informação, o modelo de melhor qualidade e simplicidade segundo o AIC é o IV; por outro lado, de acordo com o BIC, é o V. Por último, podemos olhar para a raiz do erro quadrático médio calculado dentro da amostra, que nos indica que o modelo IV é o de melhor capacidade de predição.

Posteriormente, foram utilizadas as quatro observações seguintes (de setembro de 2020 até junho de 2021) para a comparação do erro do modelo fora da amostra. Tendo em mente que o ano de 2020 foi extremamente atípico em termos de inflação, foram avaliados também as previsões de períodos pré-pandemia, a despeito da perda do número de observações.


Gráficos 13 e 14 - Projeção ARIMA IV e V



Fonte: Elaborado pela autora.

Nos gráficos acima (Gráficos 13 e 14) é possível perceber que ambos os ARIMAs subestimaram o crescimento da inflação, principalmente após o terceiro trimestre de 2020. Esse foi exatamente o período em que se iniciou a reabertura no país, e a dinâmica inflacionária, antes relativamente suprimida pelas restrições à mobilidade, voltou de forma mais acelerada. Considerando o período anterior a 2020, ou seja, estimando o ano de 2019 fora da amostra, temos um erro bastante reduzido, e as projeções estão em linha com o movimento do índice - como mostram os gráficos e a tabela abaixo (Gráficos 15 e 16, Tabela 3).

Gráficos 15 e 16 - Projeção ARIMA IV e V



Fonte: Elaborado pela autora.

Tabela 3 - Raiz do Erro Quadrático Médio (ARIMA)

Tabela 3 - RMSE		
Período de Estimação	IV	V
set/20 - jun/21	3.88	3.91
mar/19 - dez/19	1.21	1.19

Fonte: Elaborado pela autora.

4.2.2 Modelo VAR

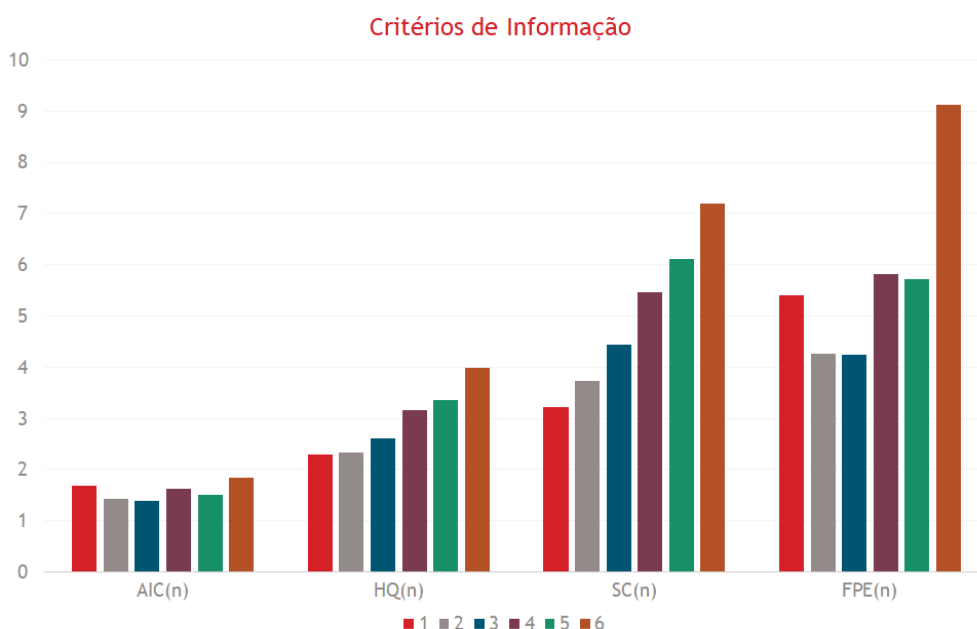
O modelo VAR, conforme especificado na seção de Metodologia, é composto de cinco variáveis principais: a inflação, a expectativa de inflação, o hiato do produto, o câmbio e a incerteza. Não foram realizados testes de cointegração uma vez que três das séries são $I(0)$, ou seja, estacionárias em nível. Além disso, o hiato do produto foi incluído com 1 período de defasagem em relação a outras variáveis, uma vez que existe um intervalo de tempo até que as pressões de capacidade produtiva gerem efeitos nos preços da economia como um todo.

Durante as tentativas de estimação, foi verificado que a inclusão de variáveis *dummy* sazonais limitavam o problema de autocorrelação dos resíduos, apesar de não serem todas significativas na equação. Por isso, foram incluídas três *dummies* trimestrais e uma de *dummy*

de quebra estrutural a partir de 2014, cuja necessidade foi identificada na análise do hiato no segmento de Análise Preliminar das Variáveis.

Assim como no ARIMA, foram testadas diferentes *lags* para as variáveis endógenas, ou seja, excluindo as *dummies*, utilizando quatro tipos de critério de informação para escolher os modelos a serem avaliados. No gráfico abaixo (Gráfico 17), foi verificado o resultado destes testes, considerando o *lag* máximo igual a 6. A amostra usada inicialmente foi de março de 2000 até junho de 2020, deixando os quatro trimestres à frente - até junho de 2021 - para comparação da estimação fora da amostra.

Gráfico 17 - Critérios de Informação



Fonte: Elaborado pela autora.


Selecionando os menores valores para cada um dos critérios, temos que o AIC e o FPE mostram melhor performance de 3 defasagens, enquanto pelo HQ e o SC apenas um seria escolhido. Em seguida, foram estimados os dois modelos, aplicando em cada um os testes de especificação adequados e foi comparada a *performance* de cada um deles na estimação da equação do IPCA, em particular (Tabela 4).

Tabela 4 - Comparativo VAR		
	VAR(3)	VAR(1)
Testes de Especificação		
ARCH LM	0.6193	0.3711
Portmanteau Ajustado		
4 lags	0.008699	0.006702
8 lags	0.0589	0.118
Equação do IPCA		
R ²	0.5731	0.4215
R ² Ajustado	0.4356	0.3482
RMSE	2.897248	2.906327

Fonte: Elaborado pela autora.

Conforme a tabela acima (Tabela 4), nenhum dos dois modelos rejeitou a hipótese nula de que os erros são homocedásticos, já que os p-valores se mantiveram bastante acima de 5%. Por outro lado, ambos apresentaram autocorrelação no teste Portmanteau Ajustado para 4 lags, porém não para 8 lags. Quanto às projeções, ambos apresentaram a raiz do erro quadrático médio bastante elevada. Os gráficos abaixo (Gráficos 18 e 19) mostram a trajetória das projeções contra o realizado, considerando o IPCA diferenciado 1 vez. Ambas subestimaram muito a trajetória da inflação no Brasil.

Gráficos 18 e 19 - VAR(3) e VAR(1)



Fonte: Elaborado pela autora.

Utilizando uma amostra até 2018 e estimando o ano de 2019, temos resultados diferentes, ainda que com uma projeção que subestima muito o IPCA. Os critérios de


informação continuam mostrando preferência pelos mesmos *lags*, e na Tabela 5 podemos ver os resultados.

Tabela 5 - Comparativo VAR		
	VAR(3)	VAR(1)
Testes de Especificação		
ARCH LM	0.9885	0.9456
Portmanteau Ajustado		
4 lags	0.003953	0.0003864
8 lags	0.1007	0.0713
Equação do IPCA		
R ²	0.6335	0.5093
R ² Ajustado	0.5021	0.4413
RMSE	2.064571	2.068495

Fonte: Elaborado pela autora.

Enquanto o poder de explicação do modelo, expresso pelo aumento R², melhorou consideravelmente, o RMSE continua bastante alto, subestimando a inflação (Gráficos 20 e 21). As conclusões sobre autocorrelação e heterocedasticidade não mudam.

Gráficos 20 e 21 - VAR(3) e VAR(1)



Fonte: Elaborado pela autora.

4.2.3 Modelo BSM

O BSM, como mencionado anteriormente, é um modelo de Estado de Espaço univariado, e foi estimado com a série do IPCA em primeira diferença pelo caráter não estacionário da série. Inicialmente, o período de estimação utilizado foi de março de 1998 até

junho de 2020, assim como o ARIMA. O modelo não apresentou problemas de autocorrelação dos resíduos ou heterocedasticidade³.

A técnica permite a decomposição da variável em nível, inclinação e sazonalidade, conforme o Gráfico 22. Nele, podemos identificar uma mudança de nível da inflação durante o período de 2015, marcado por grande incerteza política e turbulência econômica. Além disso, também a partir desse ano a sazonalidade parece aumentar, o que pode ser efeito de mudanças na representatividade de componentes na cesta do consumidor, bem como modificações nos padrões sazonais dos componentes. No estudo especial publicado pelo Banco Central do Brasil em setembro de 2018 intitulado “Evolução da sazonalidade do IPCA”, é possível identificar pela análise, nesse período, contribuições maiores dos itens “Energia Elétrica Residencial” e “Gasolina”.

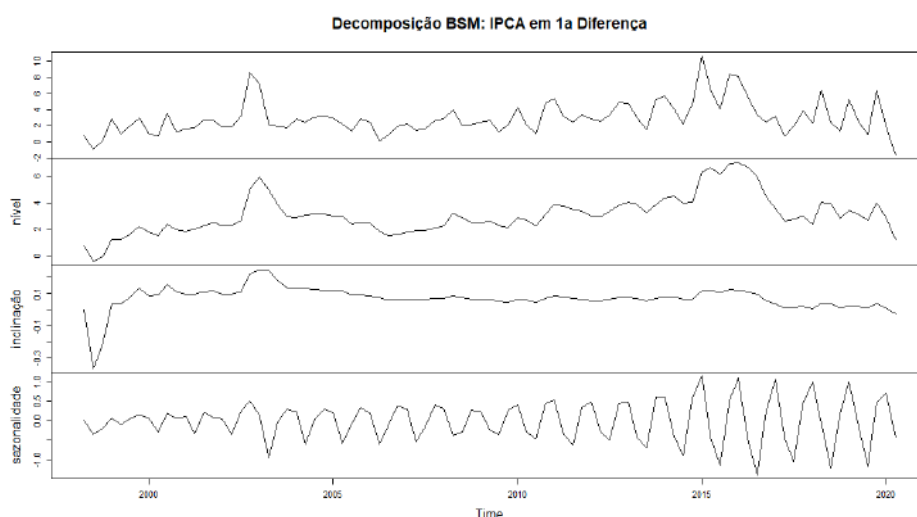



Gráfico 22 - Decomposição BSM

Fonte: Elaborado pela autora.

A partir da análise das projeções fora da amostra, de setembro de 2020 a junho de 2021, vemos que a projeção do modelo subestimou muito a inflação do período (Gráfico 23).

³ Ambos os modelos de Estado de Espaço - BSM e ETS, que será apresentado à frente - apresentaram p-valores maiores que 10% no teste Ljung-Box, não sendo possível rejeitar a hipótese nula de ausência de autocorrelação dos resíduos. No teste Breusch Pagan, ambos apresentaram p-valores acima de 30%, o que significa que não foi possível rejeitar a hipótese nula de que os erros são homocedásticos.


Gráfico 23 - Projeção Modelo BSM



Fonte: Elaborado pela autora

Assim como nos outros modelos, foram testados outros horizontes de projeção, considerando potenciais efeitos prejudiciais de um momento tão atípico para o índice de preços no país e no mundo. No Gráfico 24 temos a projeção para o ano de 2019 fora da amostra. Desta vez, a projeção está em linha com o realizado, e apesar de ter apresentado uma trajetória mais suave do que o dado, seus intervalos de confiança abrangem a variação do IPCA ao longo de todo o intervalo. Os erros de ambas as projeções serão comparados posteriormente junto ao modelo ETS.

Gráfico 24 - Projeção Modelo BSM




Fonte: Elaborado pela autora

4.2.4 Modelo ETS

O modelo ETS também é um modelo de Estado de Espaço e seu desenvolvimento acontece de forma bastante similar ao modelo BSM. Este também utiliza o IPCA na primeira diferença e foi estimado a princípio de março de 1998 a junho de 2020. Todos os testes de especificação foram realizados e não foram encontrados problemas relacionados à heterocedasticidade e autocorrelação.

No gráfico abaixo (Gráfico 25) é possível perceber uma grande similaridade entre as projeções apresentadas pelo ETS e pelo BSM, apesar do primeiro mostrar um erro menor, simbolizado pela maior proximidade do intervalo de confiança superior do valor realizado.


Gráfico 25 - Projeção Modelo ETS



Fonte: Elaborado pela autora.

Testando a projeção de 2019 fora da amostra, foi obtido um resultado bastante próximo do verificado na realidade (Gráfico 26). A projeção seguiu em linha com a variação verdadeira do IPCA, apesar de ter seguido uma trajetória mais suave, assim como o modelo anterior (Gráfico 24). Os intervalos de confiança das estimativas também abrangeram o realizado ao longo de todo o horizonte de projeção.

Gráfico 26 - Projeção Modelo ETS



Fonte: Elaborado pela autora.

Por último, a Tabela 6 mostra a comparação das raízes dos erros quadráticos médios dos dois últimos modelos, em ambos os intervalos de projeção. Apesar de muito próximos, foi possível verificar melhor performance do ETS nas projeções de setembro de 2020 a junho de 2021, enquanto o BSM performou melhor na estimativa feita ao longo de 2019.

Período de Estimação	BSM	ETS
set/20 - jun/21	2.595	2.581
mar/19 - dez/19	1.354	1.394


Fonte: Elaborado pela autora

4.3 Interpretação e Comparação

Nesta seção, os modelos apresentados serão comparados em termos de *performance* das estimativas. Pelo período de 2020 ter sido extremamente conturbado em termos de dinâmica inflacionária, a análise será restrita às projeções referentes à 2019.

Esse ponto já foi citado algumas vezes, e para justificá-lo de forma mais completa, podemos verificar a evolução das projeções de inflação do Focus durante o ano da pandemia. No gráfico abaixo (Gráfico 27), há uma tendência de queda forte a partir de março, seguida por relativa estabilidade e, posteriormente, uma tendência de alta a partir de 2020 que ganha aceleração significativa a partir de outubro. Este fenômeno foi fruto da reabertura do país, citada anteriormente, que revelou um descompasso entre a rápida escalada da recuperação demanda, e uma incapacidade da oferta de acompanhar o ritmo, pelo menos a curto prazo.


Gráfico 27 - Focus Mediana das Expectativas de Inflação



Fonte: BCB.

No ambiente global (Gráfico 28), a narrativa foi relativamente similar: a partir de setembro de 2020 os preços de commodities também passaram a acelerar com maior intensidade - apesar de já terem se recuperado de forma relevante do recorde de baixa atingido em abril de 2020, quando o receio de que a pandemia desencadeasse uma recessão profunda - e não necessariamente temporária - atingiu seu pico.

Gráfico 28 - Índice Mundial de Commodities do FMI



Fonte: FMI.

A raiz quadrada do erro quadrático médio foi escolhida como favorita para comparar os erros dos modelos, já que é medida na mesma unidade da variável dependente e, por isso, é mais fácil de ser interpretada. Esta métrica representa uma espécie de média da distância, normalizada, do vetor de valores previstos e do vetor de valores observados. A Tabela 7 recapitula os erros em cada um dos modelos.

Tabela 7 - Comparativo RMSE	
ARIMA V (2,1,2)	1.190
ARIMA IV (3,1,2)	1.210
BSM	1.354
ETS	1.394
VAR (3)	2.065
VAR (1)	2.068

Fonte: Elaborado pela autora.

É possível concluir os modelos univariados foram os de melhor desempenho nas estimações. Estes erros estão em termos de variação absoluta, trimestre a trimestre, do índice do IPCA normalizado de forma que março de 1998 seja igual a 100. No entanto, é mais comum olharmos para a inflação em variação anual; por isso, vamos olhar para as projeções de cada modelo e verificar a previsão da variação do IPCA acumulada ao longo de 2019, em contraste com a previsão do Focus ao fim de 2018 (Tabela 8).

Tabela 8 - Modelos versus Focus

Média da Variação Anual do IPCA em 2019		
	Projeção	Desvio
ARIMA V	3.778%	0.529%
ARIMA IV	3.685%	0.622%
BSM	3.400%	0.906%
ETS	3.359%	0.947%
VAR (3)	2.529%	1.777%
VAR (1)	2.521%	1.785%
Focus - Mediana 12 Meses à frente	3.900%	0.406%

Fonte: BCB. Elaborado pela autora.

Os erros absolutos são relevantes se tratando de projeções de inflação; é preciso notar, entretanto, que 12 meses à frente, a *performance* do Focus não foi expressivamente melhor que a do ARIMA V (2,1,2) - modelo de melhor *performance*. O VAR apresentou o pior desempenho entre as estimativas desenvolvidas e, isso pode ser explicado, em parte, pelo

baixo poder de explicação do R^2 ajustado das equações de inflação e também funções impulso-resposta, que mostraram impactos estatisticamente irrelevantes em termos absolutos na variável, apesar de, em geral, terem apresentado a direção correta indicada pela teoria.

É preciso notar que analistas profissionais do mercado financeiro e Bancos Centrais utilizam, via de regra, modelos muito mais complexos do que os aqui apresentados para prever a trajetória do IPCA. Aqui o índice foi utilizado de forma agregada, sem discriminar preços livres e preços administrados, nem foram levados em consideração idiosincrasias de itens específicos, que apresentam dinâmicas de inércia e sazonalidade distintas.

Além disso, por ser um modelo univariado, o ARIMA captura muito bem a tendência da variável, e por isso foi o de melhor *performance* em nossa projeção de curto prazo. Contudo, a grande limitação deste tipo de modelo advém da sua incapacidade de captar mudanças estruturais na atividade, dinâmica inercial de preços, comércio exterior, termos de troca etc. Por conta disso, não costuma *performar* bem em projeções um pouco mais longas, ou em momentos de virada do ciclo econômico.

5 CONCLUSÃO

Dentre os modelos apresentados, foi possível concluir que os univariados se mostraram superiores em sua capacidade de predição da inflação à frente em relação ao VAR. Analisando a estimação fora da amostra para o período de setembro de 2020 até junho de 2021, foi verificado um erro muito elevado, com todos os modelos subestimando consideravelmente a força da inflação com raízes do erro quadrático médio acima de dois.

Esse fenômeno é explicado pela aceleração forte dos preços a partir deste período, causada por um descompasso entre uma forte retomada da demanda após a flexibilização de algumas medidas de restrição impostas para frear o Covid-19 e a oferta, que não tendo se planejado para tal crescimento, não conseguiu acompanhar. Isso levou a revisões relevantes de expectativas de inflação pelos agentes de mercado e não se restringiu somente ao Brasil, como evidenciado pelo salto de preços de commodities no mesmo período.

Levando tal peculiaridade em conta, o período de estimação entre março de 2019 e dezembro de 2019 foi escolhido como o mais adequado para comparar o desempenho dos modelos elaborados. Como resultado da análise, foi possível observar que o modelo ARIMA mostrou o melhor desempenho, seguido pelos dois métodos de estado de espaço (BSM e ETS); por último, o VAR foi o modelo de pior performance, apresentando um erro ainda excessivo ainda que outro período de previsão.

A vantagem das técnicas univariadas - em especial do ARIMA - pode ser atribuída a sua capacidade de captar muito bem a dinâmica de curto prazo de uma variável inercial como o IPCA. Por isso, a inflação predita segue a tendência da de fato realizada, ainda que sem apresentar nuances - uma vez que não leva em conta outros fatores importantes para a determinação dos preços, como hiato do produto, câmbio, expectativa dos agentes etc.

Por outro lado, o VAR, apesar de ter mostrado evidências de ser um modelo bem especificado, ou seja, sem problemas de heterocedasticidade ou autocorrelação dos resíduos e funções impulso-respostas em direções condizentes com a teoria econômica, apresentou um erro muito grande, com previsões bastante abaixo do realizado. Com um R^2 relativamente baixo, as variáveis significantes acabaram mostrando um efeito bastante reduzido sobre a inflação, com impulsos-respostas que incluíam o zero dentro do intervalo de confiança - atribuindo aos impactos um valor estatisticamente igual a zero.

6 REFERÊNCIAS

HALDANE, Andrew G.; BATINI, Nicoletta. **Forward Looking Rules for Monetary Policy**. National Bureau of Economic Research - Working Paper Series, 1998. Disponível em: https://www.nber.org/system/files/working_papers/w6543/w6543.pdf.

BLANCHARD, Olivier J. **Macroeconomia**. 7ª edição. Pearson Education do Brasil Ltda, 2018.

BLANCHARD, Olivier. **European Unemployment: The evolution of facts and ideas**. Economic Policy, v1, 2006.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA – Ipeadata. **Dados macroeconômicos**. Disponível em: <http://www.ipeadata.gov.br>.

BANCO CENTRAL DO BRASIL. **Relatório de Inflação de junho de 2017**, Modelo agregado de pequeno porte. Disponível em: www.bcb.com.br.

BANCO CENTRAL DO BRASIL. **Relatório de Inflação de junho de 1999**, O mecanismo de transmissão da política monetária. Disponível em: www.bcb.com.br.

LOPES, L.M; VASCONCELLOS, M.A.S. **Manual de Macroeconomia: nível básico e nível intermediário**. 2015.

GOLDFAJN *et al.* **Implementing Inflation Targeting in Brazil**. Working Paper Series 53, Central Bank of Brazil, Research Department. Nov. 2002. Disponível em: <https://www.bcb.gov.br/pec/wps/ingl/wps53.pdf>.

BUENO, R. L. S. **Econometria de Séries Temporais**. São Paulo: Cengage Learning, 2020.

BUREAU OF LABOR STATISTICS. **Dados macroeconômicos**. Disponível em: <https://www.bls.gov/>.

BANCO CENTRAL DO BRASIL. **Evolução da sazonalidade do IPCA**. Estudos Especiais do Banco Central do Brasil, 2018. Disponível em: https://www.bcb.gov.br/conteudo/relatorioinflacao/EstudosEspeciais/Evolucao_da_sazonalidade_do_IPCA.pdf.

FRIEDMAN, Milton. **The Role of Monetary Policy**. The American Economic Review, vol. 58, no. 1, 1968.