



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO SOCIECONÔMICO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

Carlos Bruno Vieira de Arruda

**Nowcasting do PIB Brasileiro:** Estabilidade financeira e crescimento econômico

Florianópolis  
2020

Carlos Bruno Vieira de Arruda

**Nowcasting do PIB Brasileiro: Estabilidade financeira e crescimento econômico**

Dissertação submetida ao Programa de Pós-Graduação em Economia da Universidade Federal de Santa Catarina para a obtenção do título de mestre em Economia.

Orientador: Prof. Roberto Meurer, Dr.

Florianópolis  
2020

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Arruda, Carlos Bruno Vieira de  
Nowcasting do PIB Brasileiro : Estabilidade financeira  
e crescimento econômico / Carlos Bruno Vieira de Arruda ;  
orientador, Roberto Meurer, 2020.  
76 p.

Dissertação (mestrado) - Universidade Federal de Santa  
Catarina, Centro Sócio-Econômico, Programa de Pós-Graduação em  
Economia, Florianópolis, 2020.

Inclui referências.

1. Economia. 2. Nowcasting. 3. Abordagem não  
paramétrica. 4. PIB. 5. Estabilidade Financeira. I.  
Meurer, Roberto. II. Universidade Federal de Santa  
Catarina. Programa de Pós-Graduação em Economia. III. Título.

Carlos Bruno Vieira de Arruda

**Nowcasting do PIB Brasileiro:** Estabilidade financeira e crescimento econômico

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Wesley Vieira da Silva, Dr.  
Instituição UFSM

Prof. Roberto Meurer, Dr.  
Instituição UFSC

Prof. Milton Biage, Dr.  
Instituição UFSC

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Economia.

---

Coordenação do Programa de  
Pós-Graduação

---

Prof. Roberto Meurer, Dr.  
Orientador

Florianópolis, 2020.

## AGRADECIMENTOS

Gostaria de agradecer a todos que contribuíram de alguma maneira para a conclusão deste trabalho e do curso de mestrado.

Em primeiro lugar, agradeço à minha família e amigos, não só pelo apoio durante o curso, mas em toda a minha vida. Meus pais, José Carlos de Arruda e Mônica de Arruda, sempre me incentivaram ao aperfeiçoamento constante do conhecimento, e nunca pouparam esforços para me ajudar a conquistar meus objetivos; tenho certeza de que não chegaria aqui se não fosse por eles.

Um agradecimento especial à minha namorada Angelica Borges Vargas, por todo suporte e incentivo na reta final desta dissertação. Muitas vezes ela leu as diferentes versões deste trabalho, me ajudou nas revisões e a ter melhores *insights*, sua ajuda foi decisiva para a qualidade desta dissertação.

Além disso, a orientação concedida pelo Prof. Dr. Roberto Meurer foi essencial, seus conselhos foram de extrema importância no direcionamento do trabalho, construção da base teórica, escolha das variáveis utilizadas e análise dos resultados; dessa forma, agradeço imensamente por sua ajuda.

Agradeço também ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), a bolsa de mestrado foi fundamental para permitir minha dedicação as pesquisas.

Por último, agradeço aos professores presentes na banca de avaliação, seus comentários foram extremamente relevantes, e permitiram aperfeiçoar ainda mais o trabalho.

## RESUMO

Nesta dissertação foram estimados três modelos Nowcasting para o crescimento trimestral do PIB brasileiro, onde além de explorar indicadores ainda pouco utilizados em previsões de variáveis macroeconômicas do Brasil, também foi discutida a possibilidade da implementação de abordagem não paramétrica, mesmo quando se dispõe de séries de dados relativamente pequenas. Assim, foi construído um painel de dados composto por 113 indicadores mensais relativos a diversos assuntos, nos quais se destaca a inclusão de variáveis acerca da estabilidade financeira, visto o potencial de amplificação que essa tem sobre a economia como um todo. Aplicando um modelo de fatores dinâmicos e filtro de Kalman, foi possível reduzir o painel de dados, a três fatores latentes: “Fator Conjuntural”, composto pela relação de diversas variáveis, “Fator Mercado Financeiro”, constituído principalmente pela relação do mercado financeiro nacional com o mercado financeiro internacional, e o “Fator Demanda”, referente as vendas nacionais e importação brasileira. Tais fatores foram capazes de explicar de 40,2% até 45,8% da dinâmica de todo o painel. Esses fatores foram utilizados para estimação do crescimento trimestral do PIB brasileiro, com os períodos Outubro de 2007 até Setembro de 2016 dentro da amostra e Outubro de 2016 até Março de 2020 fora da amostra. No exercício fora da amostra foram realizadas previsões para os trimestre de 2017 até 2019, no qual os modelos não paramétricos demonstraram desempenho preditivo superior ao modelo paramétrico e similar/superior a média da pesquisa FOCUS (principal benchmarking).

**Palavras-chave:** Nowcasting. Modelo de fatores dinâmicos. Abordagem não paramétrica. PIB. Estabilidade financeira.

## ABSTRACT

In this dissertation, three Nowcasting models were estimated for the quarterly growth of the Brazilian GDP, in addition to exploring indicators still little used in forecasts of macroeconomic variables in Brazil, the possibility of implementing a non-parametric approach was also discussed, even when there are relatively small time series. Thus, a data panel composed of 113 monthly indicators related to various subjects was built, in which the inclusion of variables about financial stability stands out, given the potential for amplification it has on the economy as a whole. Applying a model of dynamic factors and Kalman filter, it was possible to reduce the data panel to 3 latent factors: “Conjunctural Factor”, composed by the relation of several variables, “Financial Market Factor”, constituted mainly by the relation the national financial market with the international financial market, and the “Demand Factor”, referring to national sales and Brazilian imports. Such factors were able to explain from 40.2% to 45.8% of the dynamics of the entire panel. These factors were used to estimate the quarterly growth of the Brazilian GDP, with the periods Oct/2007 to Sep/2016 within the sample and Oct/2016 to Mar/2020 outside the sample. In the out-of-sample exercise, quarterly forecasts were made from 2017 to 2019, in which the non-parametric models demonstrated a predictive performance superior to the parametric and similar/superior to the average of the FOCUS survey (main benchmarking).

**Keywords:** Nowcasting. Dynamic factor models. nonparametric approaches. GDP. Financial stability.

## LISTA DE FIGURAS

Figura 1 – Fluxograma do método . . . . .	23
Figura 2 – X em $\mathbb{R}^n$ . . . . .	25
Figura 3 – X representado em $F_1$ . . . . .	25
Figura 4 – Crescimento trimestral do PIB x Patrimônio Líquido/Ativos . . . . .	36
Figura 5 – Crescimento trimestral do PIB x Rentabilidade dos bancos . . . . .	37
Figura 6 – Crescimento trimestral do PIB x participação % do Ativos Nível II . . . . .	37
Figura 7 – Peso das variáveis no Fator 1 (Conjuntural) - Março/2020 . . . . .	42
Figura 8 – Peso das variáveis no Fator 2 (Mercado financeiro) - Março/2020 . . . . .	42
Figura 9 – Peso das variáveis no Fator 3 (Demanda) - Março/2020 . . . . .	43
Figura 10 – Fatores estimados - 2007 a 2020 . . . . .	44
Figura 11 – PIB estimado dentro da amostra - Now <sub>IC</sub> (Março/2020) . . . . .	45
Figura 12 – Comportamento dos parâmetros no modelo Now <sub>IC</sub> . . . . .	45
Figura 13 – Comportamento dos parâmetros no modelo Now <sub>II</sub> . . . . .	46
Figura 14 – Erro médio (%) . . . . .	47
Figura 15 – Atualizações das previsões - 1 <sup>o</sup> T 2017 . . . . .	70
Figura 16 – Atualizações das previsões - 2 <sup>o</sup> T 2017 . . . . .	71
Figura 17 – Atualizações das previsões - 3 <sup>o</sup> T 2017 . . . . .	71
Figura 18 – Atualizações das previsões - 4 <sup>o</sup> T 2017 . . . . .	72
Figura 19 – Atualizações das previsões - 1 <sup>o</sup> T 2018 . . . . .	72
Figura 20 – Atualizações das previsões - 2 <sup>o</sup> T 2018 . . . . .	73
Figura 21 – Atualizações das previsões - 3 <sup>o</sup> T 2018 . . . . .	73
Figura 22 – Atualizações das previsões - 4 <sup>o</sup> T 2018 . . . . .	74
Figura 23 – Atualizações das previsões - 1 <sup>o</sup> T 2019 . . . . .	74
Figura 24 – Atualizações das previsões - 2 <sup>o</sup> T 2019 . . . . .	75
Figura 25 – Atualizações das previsões - 3 <sup>o</sup> T 2019 . . . . .	75
Figura 26 – Atualizações das previsões - 4 <sup>o</sup> T 2019 . . . . .	76

## LISTA DE TABELAS

Tabela 1 – <i>Kernels</i> comuns . . . . .	34
Tabela 2 – Categorias das variáveis explicativas . . . . .	35
Tabela 3 – Peso médio das variáveis nos fatores - Março/2020 . . . . .	40
Tabela 4 – Resultados médios dentro da amostra . . . . .	44
Tabela 5 – Comparação do erro quadrático médio . . . . .	48
Tabela 6 – Comparação da variância do erro quadrático . . . . .	49
Tabela 7 – Valores $p$ Teste Diebold-Mariano . . . . .	50
Tabela 8 – Lista das variáveis explicativas . . . . .	61
Tabela 9 – Estatísticas descritivas das variáveis . . . . .	64
Tabela 10 – Teste KPSS . . . . .	67

## LISTA DE ABREVIATURAS E SIGLAS

a.a.	Ao ano
ARIMA	Modelo autoregressivo com média móvel e diferenciação
BACEN	Banco Central do Brasil
BRIC+M	Brasil, Rússia, Índia, China e México
BVAR	Modelo Bayesiano de vetores autoregressivos
CDI	Certificados de depósito interbancário
CRC	Central de riscos
DFM	Modelo de fatores dinâmicos (Dynamic factor models)
DI	Depósitos interfinanceiros
DM	Teste Diebold-Mariano
DMA	Combinação dinâmica de modelos (Dynamic model averaging)
DMS	Seleção dinâmica de modelos (Dynamic model selection)
EQM	Erro quadrático médio
FAVAR	Modelo de vetores autoregressivos aumentado por fatores
GW/h	Gigawatt-hora
IBC-BR	Índice de atividade econômica do Banco Central
IPCA	Índice de preços ao consumidor amplo
MAPE	Média percentual absoluta dos erros (Mean absolute percent error)
MIDAS	Modelos de dados com frequência mista
PCA	Análise de componentes principais (Principal component analysis)
PIB	Produto interno bruto
PLA/ATA	Patrimônio líquido / Ativos
PR	Patrimônio de referência
Rent AT	Rentabilidade dos ativos
Rent PL	Rentabilidade do patrimônio líquido

SARIMA	Modelo autoregressivo com média móvel, diferenciação e sazonalidade
SCR	Sistema de informações de crédito
SELIC	Sistema especial de liquidação e custódia
SEQ	Soma do erro quadrático
SPB	Sistema de pagamentos brasileiro
TVP	Parâmetros variantes no tempo (Time varying parameters)
TVP-VAR	Modelo de vetores autoregressivos com parâmetros variantes no tempo
u.m.c.	Unidade monetária corrente
UCI	Utilização da capacidade instalada
VAR	Modelo de vetores autoregressivos
Var.	Variação

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>12</b>
<b>2</b>	<b>REVISÃO DE LITERATURA</b> . . . . .	<b>15</b>
2.1	MODELOS NOWCASTING . . . . .	15
2.2	ESTABILIDADE FINANCEIRA E CRESCIMENTO ECONÔMICO . .	19
<b>3</b>	<b>METODOLOGIA</b> . . . . .	<b>23</b>
3.1	ANÁLISE DE COMPONENTES PRINCIPAIS . . . . .	24
3.2	MODELO DE FATORES DINÂMICOS . . . . .	26
3.3	FILTRO DE KALMAN . . . . .	28
3.4	ABORDAGEM NÃO PARAMÉTRICA . . . . .	30
<b>3.4.1</b>	<b>Regressão Multivariada</b> . . . . .	<b>32</b>
<b>4</b>	<b>DADOS</b> . . . . .	<b>35</b>
<b>5</b>	<b>RESULTADOS</b> . . . . .	<b>40</b>
5.1	COMPARAÇÃO DE PREVISÕES . . . . .	46
<b>6</b>	<b>CONCLUSÃO</b> . . . . .	<b>52</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>54</b>
	<b>APÊNDICE A – VARIÁVEIS UTILIZADAS</b> . . . . .	<b>60</b>
	<b>APÊNDICE B – ESTATÍSTICAS DESCRITIVAS DAS VARIÁVEIS</b> .	<b>64</b>
	<b>APÊNDICE C – TESTE DE ESTACIONARIEDADE</b> . . . . .	<b>67</b>
	<b>APÊNDICE D – ATUALIZAÇÃO DAS PREVISÕES</b> . . . . .	<b>70</b>

## 1 INTRODUÇÃO

Com uma dinâmica econômica cada vez mais acelerada e complexa, a obtenção de informações, bem como sua análise, para tomada de decisões rápidas é imprescindível. Nesse contexto, como diversas variáveis macroeconômicas são divulgadas com uma grande defasagem, previsões quanto ao estado presente dessas variáveis são um dos principais desafios dos agentes econômicos, sobretudo para o mercado financeiro e formuladores de políticas econômicas.

Entretanto, construir previsões precisas é uma tarefa muito difícil, principalmente quando se trata de uma grande variável agregada como o Produto Interno Bruto (PIB), há inúmeras variáveis que podem afetá-la, além da avaliação subjetiva das informações pelos agentes econômicos, sem mencionar problemas quanto à disponibilidade de informação, revisões de variáveis já divulgadas, e outros problemas relacionados à qualidade dos dados.

Na busca por enfrentar essas dificuldades, uma ampla gama de modelos de previsão vêm sendo desenvolvidos, entre eles, um que tem ganho destaque é o modelo Nowcasting, que tem como objetivo utilizar o máximo possível de informações disponíveis para a realização da previsão. A proposta do Nowcasting é utilizar indicadores de maior frequência (mensais, semanais, diários ou até em tempo real) para a atualização da previsão de indicadores econômicos de baixa frequência, como o PIB por exemplo, que normalmente é trimestral e tem sua divulgação com vários meses de defasagem em relação ao período de referência.

Em sua maioria, os modelos Nowcastings são compostos por três equações: equação de mensuração, equação de transição e equação *bridge*, as duas primeiras têm o objetivo de compactar a dinâmica de um grande painel de dados em poucos fatores latentes, enquanto a equação *bridge* linka os fatores estimados à variável que se pretende estimar. Diversas metodologias já foram aplicadas sobre essas equações na busca por previsões mais assertivas, ver [Bańbura et al. \(2013\)](#) para um bom apanhado dos diferentes tipos de metodologias já aplicadas. Mais recentemente a literatura começou a trabalhar com parâmetros variantes no tempo (TVP), como é o caso de [Thorsrud \(2016\)](#), que utiliza *thresholdings* para esta dinâmica.

Segundo [Henderson e Parmeter \(2015\)](#) outra metodologia para trabalhar com parâmetros variantes no tempo, ainda pouco explorada na literatura sobre previsões, é a abordagem não paramétrica. Além de suprir a necessidade dos parâmetros variarem no tempo, nessa abordagem não se assumem grandes hipóteses difíceis de satisfazer sobre a função de regressão, mas apenas suposições mínimas, deste modo, tonando os modelos capazes de chegar mais próximos das distribuições reais dos parâmetros estimados. Dessa forma, a utilização da abordagem não paramétrica em modelos Nowcastings se mostra como uma oportunidade de pesquisa.

Além disso, diante de toda a possibilidade da utilização de vários indicadores, modelos Nowcasting ainda estão explorando relativamente pouco isso, principalmente para se trabalhar com séries temporais mais longas e de fontes oficiais (Thorsrud (2016)). Com isso, diversos indicadores importantes que foram criados recentemente estão sendo deixados de lado, como é o caso no Brasil das variáveis sobre estabilidade financeira, cujo a maioria tem início no ano 2000.

No que tange a estabilidade financeira, é válido observar que há uma vasta literatura sobre os benefícios do sistema financeiro moderno para a economia (ver a Seção 2.2), benefícios esses que permitiram grandes crescimentos econômicos e aumento do bem-estar da sociedade, percebidos no mundo todo. O sistema financeiro tem o poder de amplificar os resultados da economia real. Por outro lado, ele pode se tornar fonte de instabilidades e impedir o bom funcionamento da economia. Dessa forma, a estabilidade financeira se mostra como um fator vital, e de difícil manutenção, nesse sentido, é evidente a importância da estabilidade financeira para o crescimento econômico e do monitoramento de variáveis chave sobre a estabilidade e do funcionamento do sistema financeiro.

Segundo Sidney (2017), pode-se perceber que o governo brasileiro está cada vez mais focado na estabilidade financeira, desde 1995, com o sucesso do plano real em conter a inflação, é possível observar mudanças significativas na política econômica brasileira, que aos poucos foi deixando de ser reativa e se tornou proativa. A forma de condução da política econômica, que antes era através de medidas conjunturais com intervenção sobre problemas específicos, passou a ser estrutural e com foco em estabilidade financeira, no monitoramento, controle e mitigação do risco.

Como principais medidas de políticas econômicas para a estabilidade financeira no Brasil, pode-se citar a adequação do sistema financeiro ao Basiléia I em 1994 até 2001, a qual teve foco no requerimento de capital, a criação da central de riscos (CRC) em 1997, a implementação do regime de metas de inflação e câmbio flutuante em 1999, a lei de responsabilidade fiscal em 2000, a reestruturação do Sistema de Pagamentos Brasileiro (SPB) em 2002, a substituição do CRC pelo Sistema de Informações de crédito (SCR) em 2008, a adequação ao Basiléia II em 2006 até 2009, com foco em gerenciamento de risco, e posteriormente ao Basiléia III em 2013 até 2019, para a qualidade do crédito. Os bons fundamentos macroeconômicos brasileiros e a consistência das políticas econômicas adotadas, apoiaram a atuação tempestiva das autoridades contra crises de confiança domésticas, a crise financeira de 2008, e recentemente, ao início de um processo inflacionário e baixo crescimento econômico. (Bacen (2002), Bacen (2009), Bacen (2019))

Assim, visto a necessidade de previsões eficazes de variáveis macroeconômicas e a importância da estabilidade financeira para o crescimento econômico, essa pesquisa teve como objetivo central discutir os impactos da estabilidade financeira no

crescimento trimestral do PIB brasileiro, através de modelos Nowcastings com equação *bridge* paramétrica e não paramétrica. Para isso, foram necessários os seguintes objetivos específicos:

- Construção de painel de dados, com variáveis relevantes para as movimentações do PIB;
- Simulação de dados conforme defasagem de divulgação dos diferentes indicadores;
- Modelagem dos Nowcastings;
- Análise do peso das variáveis, tanto na construção dos modelos, quanto na atualização de suas previsões;
- Comparações entre os modelos paramétricos e não paramétricos;
- Comparação do poder de previsão dos Nowcastings com técnicas padrão de séries temporais e a pesquisa FOCUS de expectativas do mercado.

Esta dissertação está dividida em seis capítulos, da seguinte forma: além desta introdução, na primeira parte do [Capítulo 2](#) é realizada a revisão de literatura sobre modelos Nowcasting, contemplando sua definição e também resultados de modelos implementados no Brasil e no mundo; na segunda parte é discutida a estabilidade financeira e seus impactos sobre o crescimento econômico. No [Capítulo 3](#) é demonstrada a metodologia utilizada nesta pesquisa, o modelo Nowcasting é estimado em três estágios, inicialmente é utilizado o modelo de fatores dinâmicos (DFM) para construção de fatores, então esses fatores são suavizados e atualizados utilizando o Filtro de Kalman, no último estágio os fatores são utilizados para estimar o crescimento trimestral do PIB brasileiro. Após isso, no [Capítulo 4](#) são apresentados os dados utilizados nesta pesquisa, além de uma breve discussão sobre algumas variáveis de estabilidade financeira. No [Capítulo 5](#) são apresentados os resultados dos modelos Nowcastings, inicialmente é realizada a discussão sobre os pesos das variáveis na construção dos fatores, em seguida, as previsões dos modelos são comparadas com os *benchmarks*. Por fim, no [Capítulo 6](#) é realizada a conclusão, com discussão dos principais resultados e sugestões para futuras pesquisas.

Esta dissertação visou realizar duas contribuições importantes para a literatura: em primeiro lugar com a análise de variáveis ainda pouco exploradas em modelos Nowcasting, sobretudo no Brasil. Em segundo lugar, com a utilização de abordagem não paramétrica em um modelo Nowcasting.

## 2 REVISÃO DE LITERATURA

### 2.1 MODELOS NOWCASTING

Os avanços em tecnologia da informação permitiram não só um número muito maior de séries econômicas disponíveis, mas também séries com frequências muito maiores (séries diárias ou até em tempo real), simultaneamente o desenvolvimento computacional permitiu o desenvolvimento de vários modelos econométricos para lidar com a grande dimensionalidade de séries para previsão de variáveis econômicas.

Porém a utilização de tais variáveis traz consigo uma série de desafios para o desenvolvimento de boas previsões econômicas, o aumento da quantidade e complexidade de dados aumenta a complexidade dos modelos, com um alto número de parâmetros a serem estimados. Por um lado, usar um modelo excessivamente simplificado pode levar a erros de especificação, por outro lado, lidar com grandes conjuntos de dados pode levar a um crescimento exponencial do número de parâmetros, resultando em estimações pouco confiáveis e instáveis, o que é conhecido como “maldição da dimensionalidade” (Giannone *et al.* (2008)).

Além disso, segundo Castle *et al.* (2013) os próprios indicadores trazem uma série de desafios para a modelagem, sendo os principais:

1. Dados ausentes: falha de informação de alguns indicadores;
2. *Delay* na divulgação: diferença de tempo entre a publicação dos diversos indicadores;
3. Mudança nos dados: atualização ou correção dos dados já publicados;
4. Erro de medição: falta de acurácia dos dados preliminares;
5. Quebra estrutural: mudanças nas médias das variáveis analisadas;
6. Necessidade de utilização de mais variáveis que observações;
7. Falta de sincronia na divulgação de indicadores: atrasos de publicação diferentes a cada lançamento.

Para contornar esses problemas, alguns modelos vêm sendo amplamente utilizados na literatura, os quais visam reduzir a quantidade de parâmetros a serem estimados e/ou lidar com os problemas ligados aos indicadores, dessa forma, transformar a “maldição da dimensionalidade” em uma “bênção”, obtendo de maneira parcimoniosa as principais características da interação de um grande painel de dados. Como exemplo tem-se os vetores autorregressivos Bayesiano (BVAR), modelos de fatores dinâmicos (DFM), modelos VAR aumentados com fatores dinâmicos (FAVAR), modelos VAR com parâmetros variantes no tempo (TVP-VAR), modelos de dados com

frequência mista (MIDAS), combinação dinâmica de modelos (DMA) e seleção dinâmica de modelos (DMS). Embora tais modelos tenham demonstrado bons resultados, não necessariamente eles conseguem contornar todos os problemas apresentados e algumas vezes a análise de resultados, sobretudo do impacto de diferentes variáveis, é muito complexa.

Outros modelos que se mostraram como uma boa alternativa são os modelos Nowcasting, que combinam a simplicidade do espaço de estado dos modelos de fatores dinâmicos (DFM) e sua capacidade de síntese de múltiplas variáveis em poucos fatores, com um sistema de filtragem (geralmente o filtro de Kalman), o que permite à atualização constante do espaço de estado e projeções do modelo. Dessa forma, esses modelos são capazes de trabalhar com todos os desafios apresentados anteriormente.

Conforme [Giannone et al. \(2008\)](#), modelos DFM são particularmente adequados para transmissão e monitoramento de condições macroeconômicas em tempo real, porque esses modelos são naturalmente convertidos em forma de espaço de estado e, portanto, a inferência pode ser realizada usando técnicas de filtragem Kalman, que por sua vez, fornecem uma solução conveniente e natural para lidar com as irregularidades dos dados e atualização das previsões. De fato, o filtro de Kalman trata os dados recebidos de maneira coerente e intuitiva: atualiza as previsões recursivamente, ponderando os componentes de inovação dos dados recebidos com base em sua pontualidade e qualidade. Além disso, como o modelo produz previsões para todas as variáveis simultaneamente, a análise do fluxo de dados não requer a modelagem de modelos separados e não relacionados.

Assim, cabe elucidar que *Nowcasting* é um termo derivado da junção de duas palavras: *now*(agora) e *forecasting*(previsão). [Bańbura et al. \(2013\)](#) definem Nowcasting como a previsão do presente, do passado recente e do futuro próximo, devido a tais modelos apresentarem bons resultados para projeção de curto prazo. Tratam-se de previsões em alta frequência, onde os modelos são atualizados constantemente, conforme diferentes indicadores são divulgadas.

O modelo Nowcasting tem como objetivo utilizar o máximo possível de informações disponíveis para a realização da previsão, sua proposta é utilizar indicadores de maior frequência (mensais, semanais, diários ou até em tempo real) para a atualização da previsão de indicadores econômicos de baixa frequência, como o PIB por exemplo, que normalmente é trimestral e tem sua divulgação com vários meses de defasagem em relação ao período de referência.

Seja  $v$  a data em que os dados foram coletados. O conjunto de informações disponíveis em  $v$  é:

$$\Omega_v = \{x_{it|v}, i = 1, \dots, n, t = 1, \dots, T_{iv}\} \quad (1)$$

Onde  $i$  identifica as  $n$  variáveis e  $t = 1, \dots, T_{iv}$  é o tempo desde a primeira até

a última observação disponível, o que depende tanto da série  $i$ , quanto da data de extração  $v$ . Seja  $y_t$  a série econômica a qual se pretende prever, limitada pelo conjunto de informações  $\Omega_v$ , a esperança condicional de  $y_t$  na data  $v$  é:

$$\hat{y}_{t|v} = \mathbb{E}[y_t|\Omega_v] \quad (2)$$

Quando há novas divulgações de indicadores, o conjunto de informações é atualizado para outra data  $w$ . Dessa forma, a nova esperança é:

$$\hat{y}_{t|w} = \mathbb{E}[y_t|\Omega_w] \quad (3)$$

Dado que  $\Omega_v \subset \Omega_w$ , presume-se que a estimativa  $\hat{y}_{t|w}$  é melhor do que  $\hat{y}_{t|v}$ , sendo mais próximo do verdadeiro valor  $y_t$ . Visto isso, é possível demonstrar o impacto da divulgação de informações, dividindo  $\hat{y}_{t|w}$  em dois componentes:

$$\mathbb{E}[y_t|\Omega_w] = \mathbb{E}[y_t|\Omega_v] + \mathbb{E}[y_t|I_w] \quad (4)$$

A segunda parte do lado direito refere-se às novas notícias divulgadas na data  $w$ , sendo  $I_w$  o conjunto de indicadores em  $\Omega_w$  que é ortogonal à  $\Omega_v$ <sup>1</sup>. Conforme [Bańbura et al. \(2013\)](#), o impacto da atualização com as novas notícias depende tanto do tamanho das notícias quanto da relevância para a variável de destino.

Essa dinâmica de estimações e atualizações em tempo real do modelo utilizando um conjunto incompleto de informações é o Nowcasting em si.

A utilização de modelos Nowcasting para a previsão da variação de fatores climáticos é comum há algum tempo, na área de economia seu uso é relativamente recente para a previsão de variáveis macroeconômicas. [Bańbura et al. \(2013\)](#) demonstram que este tipo de modelagem tem melhor desempenho quando é considerado um horizonte relativamente curto de tempo, em particular do período atual, e o procedimento estatístico é tão consistente quanto os modelos de previsões tradicionais. Além disso, a assertividade da previsão aumenta consideravelmente ao final dos períodos, indicando a importância de atualização das informações tão logo estejam disponíveis.

Há trabalhos na literatura com foco na previsão de diferentes variáveis macroeconômicas, como PIB americano e europeu ([Bańbura et al. \(2013\)](#), [Giannone et al. \(2008\)](#) e [Giannone et al. \(2017\)](#)), PIB da China ([Yiu e Chow \(2011\)](#)), PIB da Noruega ([Aastvei e Trovik \(2010\)](#) e [Thorsrud \(2016\)](#)), PIB da Turquia ([Modugno et al. \(2016\)](#)), inflação anual americana ([Giannone et al. \(2006\)](#)), ciclos econômicos ([D'Agostino et al. \(2015\)](#)) e previsão de crescimento econômico global ([Ferrara e Marsilli \(2014\)](#)).

[Liu et al. \(2011\)](#) desenvolveram cinco modelos de previsões e nowcasting do PIB de dez países da América Latina, os autores verificaram que a assertividade das

<sup>1</sup> ortogonalidade é a generalização da noção de perpendicularidade, aplicado ao contexto, as informações contidas em  $I_w$  não seriam alcançadas através de movimentos no vetor  $\Omega_v$

projeções aumenta ao final dos períodos, demonstrando a necessidade de atualização das informações. Outro resultado relevante é a importância da utilização de variáveis explicativas externas e de preços de commodities, o que indica dependência desses países à exportação.

Dahlhaus *et al.* (2015) realizaram projeções do PIB dos países Brasil, Rússia, Índia, China e México (BRIC+M). Para o Brasil os autores desenvolveram um modelo utilizando 35 variáveis, compreendendo tanto variáveis reais quanto financeiras, e é demonstrado que as projeções melhoram conforme novas informações são divulgadas, obtendo melhores resultados nos meses posteriores à realização do trimestre estimado; além disso, as variáveis financeiras perdem relevância na explicação das movimentações do PIB com as atualizações das informações.

Bragoli *et al.* (2014) demonstram que previsões geradas a partir de um modelo nowcasting para o PIB brasileiro, podem superar a média da pesquisa FOCUS de expectativas do mercado. Os autores evidenciam a importância da atualização das informações e de se trabalhar com séries de alta frequência, além disso, que as variáveis de comércio (principalmente exportação), produção industrial e emprego formal se mostram significativas na atualização do modelo.

Kagohara (2015) desenvolveu um modelo nowcasting para o Brasil, utilizando a metodologia proposta por Castle *et al.* (2013), o qual permite a utilização de defasagens do PIB e variáveis *dummies*, a pesquisa conta com um conjunto de dados formado por 72 variáveis, as quais são classificadas como reais, financeiras e commodities. Como resultado tem-se que a utilização de variáveis *dummies* não foi decisiva para definir a melhor eficácia das previsões, enquanto que a escolha da significância utilizada na estimação e no algoritmo de seleção de variáveis mostrou-se relevante. São estimados seis modelos com diferentes especificações os quais obtiveram resultados iguais ou melhores ao modelo utilizado como *benchmark* (um AR(4)).

Já Pedro Montero Mattos (2017) estima um modelo nowcasting de apenas um estágio, utilizando 20 variáveis explicativas, sendo algumas delas diárias. O resultado obtido demonstra poder de projeção similar a média da pesquisa FOCUS.

Gomes (2018) implementa três modelos, o primeiro baseado na análise de componentes principais, o segundo estimado com fatores trimestrais e o último com fatores mensais, o autor utiliza um total de 60 variáveis explicativas. Os resultados obtidos no modelo com fatores mensais superam as projeções da FOCUS nos meses posteriores a realização do trimestre, onde há uma maior quantidade de informação disponível.

Com base no acima exposto, este trabalho visa contribuir com esta literatura para o Brasil, com a implementação de modelos Nowcastings com a utilização de abordagens paramétricas e não paramétricas na equação *bridge*, além de analisar o impacto de variáveis de estabilidade financeira na construção dos fatores latentes e

nas atualizações de previsões. O próximo capítulo se destina a revisão de literatura acerca da estabilidade financeira e seus impactos sobre o crescimento econômico, dessa forma, justificando a utilização de tais variáveis em um modelo para previsão do PIB.

## 2.2 ESTABILIDADE FINANCEIRA E CRESCIMENTO ECONÔMICO

Há uma vasta literatura sobre os benefícios do sistema financeiro moderno para a economia, ele fornece maneiras de transformar incerteza fundamental em riscos quantificáveis e precificáveis, realiza transformação de liquidez de ativos, diversificação dos riscos, facilita as trocas, pagamentos, alocação de riqueza, formação de poupança, etc. Tais benefícios permitiram grandes crescimentos econômicos e aumento do bem-estar da sociedade, percebidos no mundo todo.

Segundo [Schinasi \(2004\)](#) o sistema financeiro amplia as oportunidades da sociedade para eficiência em processos econômicos intertemporais como comércio, produção, riqueza, acumulação, desenvolvimento e crescimento econômico e, finalmente, prosperidade social. Em suma, a aceitabilidade universal do dinheiro e a existência de um processo efetivo de financiamento, juntos criam um ambiente que fornece benefícios coletivos a todos os membros da sociedade.

Porém para fornecer tais benefícios para a economia, o sistema financeiro lida com um aspecto frágil: a confiança. Como o financiamento incorpora existencialmente a incerteza, ele mesmo pode se tornar fonte de instabilidade econômica. A confiança pode, e com bastante frequência, se tornar uma fonte de instabilidade financeira, como as dúvidas se propagam através do sistema financeiro elas podem tornar-se generalizadas, prejudiciais e talvez até sistêmicas. Por fim, como o financiamento apóia e facilita processos econômicos reais, essas instabilidades podem muito bem se estender à economia real ([Schinasi \(2004\)](#), [Large \(2003\)](#), [Wellink \(2002\)](#)).

Para [Wellink \(2002\)](#) a estabilidade financeira é uma condição vital para o crescimento econômico, já que a maioria das transações na economia real é liquidada por meio de sistema. A importância da estabilidade financeira é talvez mais visível em situações de instabilidade, quando pode ocorrer dos bancos ficarem relutantes em financiar projetos lucrativos, desvios excessivos dos preços de ativos de seus valores intrínsecos subjacentes, ou ineficiência do sistema de pagamentos. Em casos extremos, a instabilidade financeira pode até levar a corridas bancárias (quando um grande número de clientes de um banco levanta os seus depósitos porque crêem que o banco está, ou pode ficar, insolvente), hiperinflação ou uma quebra no mercado de ações.

O termo estabilidade financeira descreve um estado no qual o sistema financeiro é capaz de desempenhar com eficiência suas principais funções econômicas, como alocação de recursos, diversificação de riscos, transformação de liquidez, liquidação de pagamentos, precificação de ativos, e que acima disso, é capaz de fazê-lo

mesmo em caso de choques, situações de estresse e períodos de profundas mudanças estruturais. O continuum para a estabilidade financeira pode ser pensado como multidimensional, o qual ocorre em uma infinidade de variáveis observáveis e mensuráveis. Como continuidade, a estabilidade financeira é consistente com um sistema financeiro em perpétuo estado de fluxo e transformação, enquanto sua capacidade de executar suas funções principais permanece bem dentro de um conjunto de limites toleráveis (Chant (2003), Crockett (1997), Schinasi (2004), Bundesbank (2003), Duisenberg (2001), Wellink (2002)).

Em termos gerais, a estabilidade financeira pode ser pensada em termos da capacidade do sistema financeiro de: (a) facilitar a alocação eficiente de recursos econômicos - tanto espacial quanto, especialmente, intertemporal - e a eficácia de outros processos econômicos (como acumulação de riqueza, crescimento econômico e, finalmente, prosperidade social); (b) avaliar, precificar, alocar e gerenciar riscos financeiros; e (c) manter sua capacidade de executar essas funções - mesmo quando afetadas por choques externos ou por um acúmulo de desequilíbrios - principalmente através de mecanismos auto-correctivos (SCHINASI, 2004, p. 8).<sup>2</sup>

Manter a estabilidade financeira se mostra como o principal desafio do sistema financeiro, o qual é extremamente complexo, a estabilidade depende de diversas interações simultâneas e/ou iterativas de diferentes agentes econômicos, tanto públicos quanto privados, os quais têm diferentes interesses, acessos à informação, e capacidades financeiras. Segundo Schinasi (2004) os agentes econômicos (principalmente os públicos) enfrentam um *trade-off* entre resiliência e eficiência, ou seja, o custo da capacidade de reação contra choques, que possam levar a instabilidades financeiras, é a formação de reservas e a prudência na diversificação de riscos, o que pode reduzir a capacidade de ampliar o crescimento econômico. Além disso, a instabilidade financeira pode ser originada de diversos fatores, além de choques externos e mudanças estruturais na economia, há a possibilidade de o sistema financeiro se tornar instável de maneira endógena, através da acumulação de desequilíbrios causados por preços incorretos de ativos e/ou outras “imperfeições” de mercado. Isso é consistente com a ampla evidência histórica de que os sistemas financeiros, particularmente os bancários, são propensos à acumulação de desequilíbrios (concentrações de risco ou falta de liquidez, por exemplo) e até instabilidade. (Hyman P. Minsky (2014), Schinasi (2004), Large (2003)).

Desde o trabalho seminal de Hyman Minsky (1977) sobre ciclos comportamentais de crédito, uma ampla literatura tem demonstrado a prociclicidade do sistema financeiro, devido sobretudo a aspectos comportamentais dos agentes econômicos. Pode-se dizer que o otimismo do investidor e a redução da percepção do risco pelos intermediários financeiros, levam juntos à expansão do crédito e do investimento, porém quando há a queda desse otimismo o resultado é uma contração econômica.

---

<sup>2</sup> Tradução livre

Jorda *et al.* (2013) demonstram que expansões mais intensivas em crédito são seguidos por recessões mais profundas, Mian *et al.* (2015) que o crescimento da dívida das famílias prevê desacelerações econômicas, Baron e Xiong (2016), através de uma amostra de 20 países desenvolvidos, estabelecem que a expansão do crédito bancário prevê um aumento significativo do risco no mercado acionário, Fahlenbrach *et al.* (2016) mostram que o rápido crescimento de empréstimos prevê baixo desempenho de empréstimos e baixos retornos bancários no futuro, Greenwood e Hanson (2013) que a qualidade de crédito dos emissores de dívida deteriora-se durante os booms de crédito e essa alta parcela de empréstimos arriscados prevê retornos de títulos baixos e até negativos, López-Salido *et al.* (2017) que baixos spreads de crédito preveem um aumento nos spreads de crédito e baixo crescimento econômico, eles enfatizam a reversão a média, Gilchrist e Zakrajšek (2012) e Gilchrist e Zakrajšek (2015) estabelecem que a contração do crédito pode antecipar corretamente a próxima recessão.

Segundo Borio e White (2004) um ambiente financeiro liberalizado pode acomodar e reforçar mais facilmente as flutuações da atividade econômica. Isso pode ser feito dando impulso as poderosas forças procíclicas inerentes a acordos financeiros e em sua interação bidirecional com a economia real. O sistema financeiro é inerentemente procíclico, tanto as percepções de valor e risco quanto a disposição de correr riscos são altamente procíclicas, têm efeitos nos preços, spreads de crédito e medidas contábeis de perdas. Durante os booms, processos de auto-reforço podem se desenvolver, caracterizados pelo aumento dos preços dos ativos, afrouxamento das restrições de financiamento, aumento da produtividade e lucros. Porém esses processos operam inversamente durante as contrações, algumas das forças inversas surgem na demanda, à medida que famílias e empresas lutam para reestruturar seus balanços, apanhados entre lucros e receitas em declínio, queda dos preços de seus ativos e aumento do endividamento, outros decorrem principalmente do lado da oferta, à medida que as instituições financeiras se tornam mais cautelosas na extensão do financiamento.

Em particular, o risco é frequentemente subestimado em booms e superestimado em recessões, indicadores de percepção de risco tendem a declinar durante a alta, e em alguns casos, a serem mais baixos perto do pico do boom. Uma das consequências das práticas atuais de mensuração de risco, é que as provisões bancárias tendem a reduzir proporcionalmente ao crédito durante os booms econômicos. Esta dinâmica contribui para a prociclicidade do sistema financeiro, aumentando a ciclicidade da rentabilidade dos bancos, criando pressão adicional sobre seus balanços financeiros (Borio *et al.* (2001), Borio e White (2004), Bischof *et al.* (2018), Stein (2014)).

Conforme os bancos aumentam capital aproveitando o boom, sua exposição e riscos quanto a flutuações econômicas aumentam e, dessa forma, uma pequena contração econômica que gere inadimplências nos pagamentos de empréstimos, pode

ter grandes impactos sobre os balanços financeiros dos bancos, conduzindo-os a uma situação de alavancagem insustentável. O aumento da importância dos balanços dos intermediários sincroniza as respostas ao choque, dando mais impulso aos efeitos de realimentação na economia real. O potencial de efeitos reais adversos é especialmente forte quando os bancos respondem ao aparecimento de condições mais turbulentas, reduzindo suas exposições, com a redução de empréstimos e cobrança de prêmios de risco mais altos. O gerenciamento prudente de riscos determina tais ações, além disso, há o risco de contágio e pânico em massa, o que pode agravar a crise e torna-lá sistêmica. (Adrian e Shin (2008), Borio *et al.* (2001), Borio e White (2004), Bischof *et al.* (2018), Allen e Gale (2004)).

Segundo Brunnermeier e Sannikov (2016b) e Brunnermeier e Sannikov (2016a) os intermediários financeiros podem ser alavancados e assumem incompatibilidade de liquidez, ou seja, os seus ativos são de longo prazo e possuem baixa liquidez enquanto seu passivo é resgatável em curto prazo. Na ocorrência de uma contração econômica, o risco endógeno surge através de um mecanismo de amplificação na forma de dois espirais. Primeiro a espiral de liquidez: o impacto absorvido pelos intermediários faz com que eles busquem o reequilíbrio de seus balanços, através da venda de ativos, o que causa redução no preço dos ativos da economia (maior oferta), levando a futuras vendas de ativos. Em segundo lugar a espiral desinflacionária: na busca pelo equilíbrio financeiro, os intermediários reduzem sua exposição e financiamentos concedidos (queda no multiplicador bancário), o que tem um efeito desinflacionário, causando um novo choque no passivo dos bancos. A resposta micro-prudente dos intermediários na busca por equilibrar seus balanços leva a um risco endógeno mais alto na economia, ou seja, é macro-imprudente, um paradoxo da prudência.

Destarte, pode-se concluir que a estabilidade financeira é fundamental para o crescimento econômico, não só pelas funções que desempenha para o aumento da eficiência econômica, mas também pelo seu poder de amplificar as flutuações da economia real. Entretanto, manter a estabilidade financeira é um grande desafio, seu aspecto multidimensional e a interação entre diferentes agentes econômicos torna difícil a previsão das próximas movimentações no mercado. Com isso, a inclusão de papéis adequados para os intermediários financeiros e a utilização de variáveis de estabilidade financeira, se mostram indispensáveis para a qualidade da pesquisa econômica.

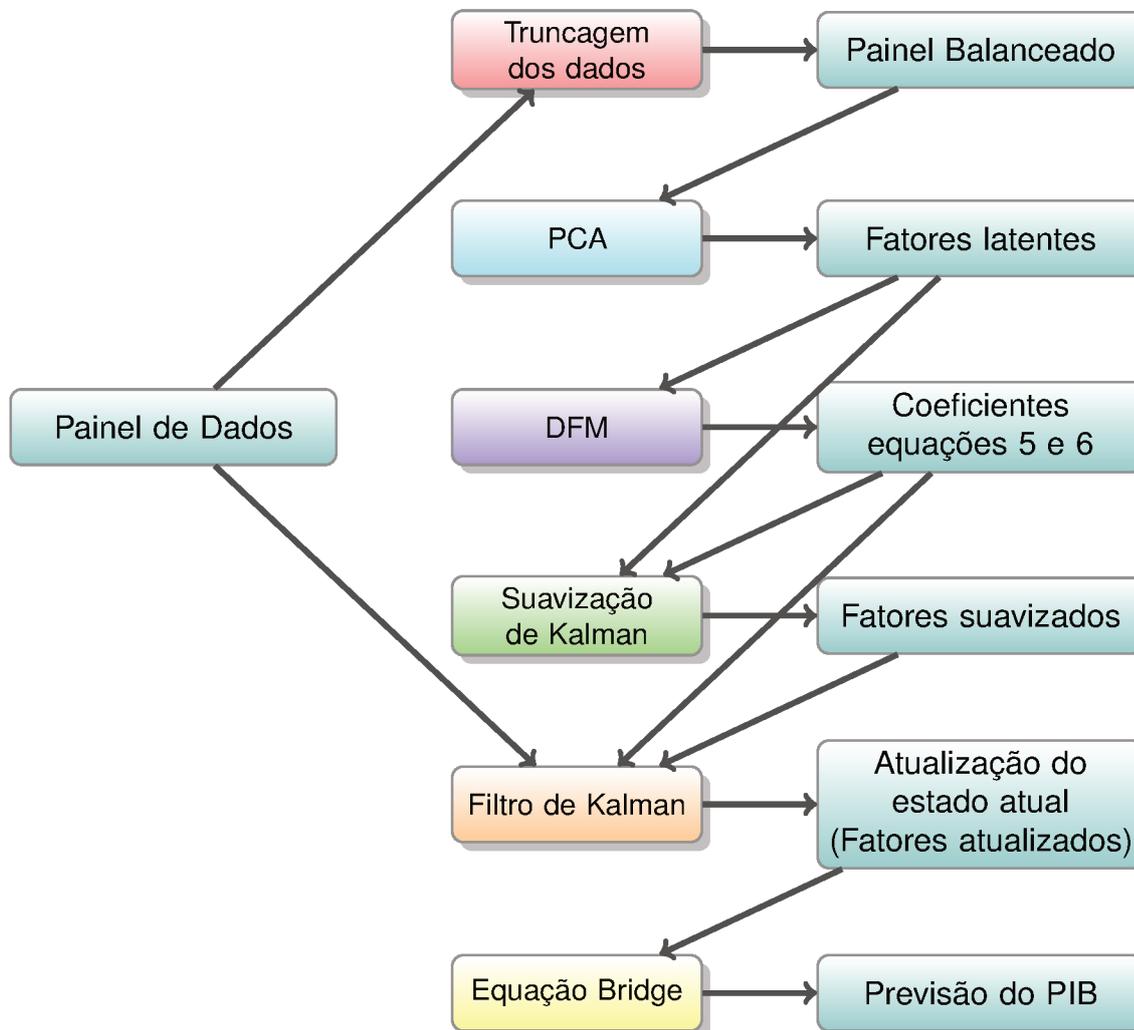
Dessa forma, a utilização de indicadores sobre a estabilidade financeira parece extremamente relevante na construção de um modelo Nowcasting que produza boas previsões para o crescimento trimestral do PIB brasileiro, não só devido ao impacto dessas variáveis sobre toda a economia, mas também por serem de frequência mensal, em sua maioria, possibilitando a atualização das previsões.

### 3 METODOLOGIA

O modelo utilizado nesta pesquisa foi proposto por [Bańbura e Rünstler \(2007\)](#), trata-se de um modelo Nowcasting para a projeção do crescimento trimestral do PIB, por meio de indicadores mensais, o qual é estimado utilizando modelo de fatores dinâmicos (DFM) e atualização por filtro de Kalman (modelo esse que constitui a base de modelos do Fed de Nova York).

Nessa dissertação, adicionalmente ao modelo de [Bańbura e Rünstler \(2007\)](#), é testada a utilização de abordagem não paramétrica na equação *bridge*, seguindo metodologia descrita em [Henderson e Parmeter \(2015\)](#).

Figura 1 – Fluxograma do método



Fonte – Elaboração Própria

Nesse sentido, a estimação do modelo é realizada em três estágios, o que o torna capaz de lidar com dados irregulares, sem descartar informações. A [Figura 1](#) demonstra as etapas do método, do lado esquerdo está a entrada do modelo, no meio

as etapas e no lado direito os resultados de cada etapa. As três primeiras etapas fazem parte do primeiro estágio, as etapas quatro e cinco do segundo estágio, enquanto a equação *bridge* é o último estágio.

Na primeira etapa de estimativa é construído um novo painel de dados truncando o painel original apenas com as informações completas, ou seja, são retiradas as últimas observações do painel de dados, onde devido aos diferentes atrasos de divulgação dos indicadores, há diversas observações ausentes.

O painel balanceado gerado pela truncagem é utilizado para a estimativa inicial dos fatores latentes via PCA, após isso, na etapa DFM são obtidas a relação desses fatores com o painel balanceado e a dinâmica de movimentação, utilizando as equações (5) e (6).

Com os coeficientes DFM e os fatores estimados, passa-se para o suavização de Kalman, a qual suaviza e melhora os fatores latentes por um processo iterativo que busca a minimização do erro da Equação (5). Em seguida, com os coeficiente DFM, fatores suavizados e o painel de dados completo como entradas, o filtro de Kalman atualiza o estado atual do modelo, ou seja, realiza a atualização dos fatores com as últimas observações do painel de dados.

Por fim, a equação *bridge* é estimada linkando o crescimento trimestral do PIB aos fatores atualizados e são geradas as previsões. Visto isso, as seções seguintes se destinam ao detalhamento de todas as etapas.

### 3.1 ANÁLISE DE COMPONENTES PRINCIPAIS

Segundo Härdle e Simar (2003), a análise de componentes principais (PCA) é um método que utiliza abordagem geométrica para redução de dimensionalidade de um painel de dados, compactando-o em poucos fatores latentes que expliquem a dinâmica do painel.

Seja  $X(t \times n)$  uma matriz com  $t$  observações de  $n$  variáveis, pode-se observar cada linha dessa matriz como um vetor  $x'_i = (x_{i1} \dots x_{in})' \in \mathbb{R}^n$ . Desse ponto de vista  $X$  é uma nuvem de  $t$  pontos em  $\mathbb{R}^n$ , ver Figura 2.

Dessa forma, a questão que se coloca é como projetar essa nuvem de pontos em um espaço com pequenas dimensões, sem perder muita informação sobre variação e estrutura desses pontos. Para fazer isso, para uma dimensão é necessário encontrar uma linha  $F_1$ , qual é definida por um vetor  $u_1 \in \mathbb{R}^n$  e que forneça o melhor ajuste para a nuvem de pontos, ver Figura 3.

A solução mais simples é encontrar o vetor  $u_1$  que maximize  $(X'u_1)'(Xu_1) = u'_1(XX')u_1$ , o que é dado pelo autovetor de  $(XX')$  correspondente ao maior autovalor  $\lambda_1$  de  $(XX')$ . Note que se os dados forem centrados, ou seja,  $\bar{x} = 0$ , então a solução refere-se a matriz de covariância de  $X$ ,  $Cov(XX')$ .

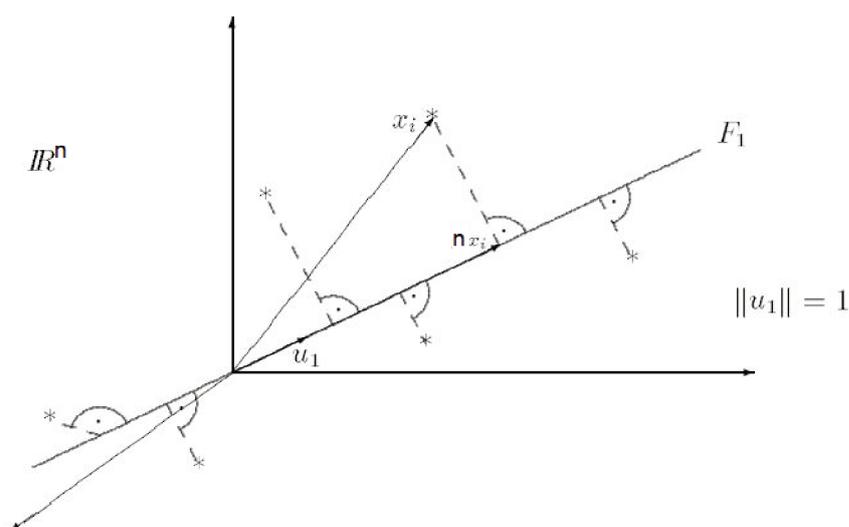
Dessa forma, as coordenadas das  $n$  variáveis em  $F_1$  são dadas por  $z_1 = Xu_1$ ,

Figura 2 – X em  $\mathbb{R}^n$



Fonte – Elaboração Própria (Adaptado de Härdle e Simar (2003))

Figura 3 – X representado em  $F_1$



Fonte – Elaboração Própria (Adaptado de Härdle e Simar (2003))

o que é conhecido como primeiro fator latente; esse é uma combinação linear das observações de cada variável pelo vetor  $u_1$  de coeficientes.

Nos casos onde se trabalha com mais dimensões, o espaço é gerado por  $u_1, u_2, \dots, u_r$  autovetores associados aos autovalores  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ .

Por fim, cabe ressaltar os seguintes pontos sobre esse modelo:

- Não são necessárias hipóteses particulares sobre X, exceto que um vetor médio e a matriz de covariância existam;

- Caso as variáveis em  $X$  não sejam estacionárias, os autovalores não serão bem definidos, o que resulta em fatores espúrios;
- Esse método é sensível as mudanças de escala das variáveis, dessa forma, a padronização é uma prática usual.

### 3.2 MODELO DE FATORES DINÂMICOS

Modelos DFM são desenhados para explicar a dinâmica em um painel de séries de dados através de poucas fontes de variação (fatores latentes), resultando em um modelo parcimonioso e utilizando toda a informação que o painel de séries contém, dessa forma, possibilita a utilização de vasta quantidade de variáveis, sem incorrer em problemas de estimação devido a grande quantidade de parâmetros. Tais benefícios dos modelos DFM foram sintetizados por [Stock e Watson \(2011\)](#) como à “bênção da dimensionalidade”. Pode-se ver que eles são um refinamento dos modelos PCA, pois trabalham a dinâmica dos fatores latentes em vez de fazer somente a análise estática.

Considere um vetor de  $n$  séries  $x_t = (x_{1,t}, \dots, x_{n,t})'$ ,  $t = 1, \dots, T$ . O DFM segundo [Doz et al. \(2006\)](#) é dado pelas seguintes equações:

$$x_t = \Lambda f_t + \xi_t, \text{ onde } \xi_t \sim \mathbb{N}(0, \Sigma_\xi), \quad (5)$$

$$f_t = \sum_{i=1}^p A_i f_{t-i} + \zeta_t, \quad (6)$$

$$\zeta_t = B\eta_t, \text{ onde } \eta_t \sim \mathbb{N}(0, I_q)$$

Por uma matriz de coeficientes de fatores  $\Lambda$ , a equação de mensuração (5) relaciona a série mensal  $x_t$  à um vetor  $r \times 1$  de fatores latentes  $f_t = (f_{1,t}, \dots, f_{r,t})'$ <sup>1</sup> mais um componente idiossincrático  $\xi_t = (\xi_{1,t}, \dots, \xi_{n,t})'$ , sendo esse último assumido como ruído branco multivariado com matriz de covariância diagonal  $\Sigma_\xi$ . Os fatores seguem um processo VAR(p) demonstrado na equação de transição (6), a qual descreve a lei de movimentação. Os fatores são movidos por ruídos brancos padronizados  $q$ -dimensional  $\eta_t$ , onde  $B$  é uma matriz  $r \times q$ , sendo  $q \leq r$ . Dessa forma,  $\zeta_t \sim \mathbb{N}(0, BB')$ . Assume-se que o processo estocástico de  $f_t$  é estacionário.

[Bańbura e Rünstler \(2007\)](#) estenderam o modelo de [Doz et al. \(2006\)](#) para combinar um modelo de fatores mensais com a projeção da média ajustada do PIB da zona do Euro em uma abordagem de frequência mista. Nesta dissertação é utilizada

<sup>1</sup> Onde  $f_t$  pode ser visto como  $f_{t|v}$ , ou seja, o fator estimado com base no conjunto de informações  $\Omega_v$

a mesma abordagem, são utilizados fatores mensais para explicar o crescimento trimestral do PIB brasileiro, a vantagem disso é utilizar indicadores com maior frequência para explicar um indicador de baixa frequência.

Para esse propósito, [Bańbura e Rünstler \(2007\)](#) introduzem a previsão do crescimento mensal do PIB como uma variável latente, que é relacionada aos fatores pela **equação bridge**:

$$\hat{y}_t = \beta' f_t \quad (7)$$

No terceiro mês de cada trimestre, é avaliada a projeção para o crescimento do trimestre,  $\hat{y}_t^Q$ , como a média trimestral da série mensal:

$$\hat{y}_t^Q = \frac{1}{3}(\hat{y}_t + \hat{y}_{t-1} + \hat{y}_{t-2}) \quad (8)$$

Defini-se o erro de projeção como  $\epsilon_t^Q = y_t^Q - \hat{y}_t^Q$ . É assumido que  $\epsilon_t^Q$  é distribuído com  $\epsilon_t^Q \sim \mathbb{N}(0, \sigma_\epsilon^2)$ . As inovações  $\xi_t$ ,  $\zeta_t$  e  $\epsilon_t^Q$  são assumidas como mutuamente independentes em todas as derivações e atrasos.

As equações (5) até (8) podem ser convertidas em forma de espaço de estado, o que é ilustrado a seguir para o caso de  $p = 1$ . Para lidar com as frequências mistas é construída uma série  $y_t^Q$  na forma mensal, de tal forma que contenha a média ajustada do crescimento trimestral do PIB no 3º mês do respectivo trimestre, sendo as observações restantes tratadas como ausentes. A última linha da [Equação \(9\)](#), relacionada a  $y_t^Q$ , é definida apenas para o 3º mês do trimestre, caso contrário é omitido na aplicação.

A regra de agregação (8) é implementada de forma recursiva na [Equação \(10\)](#), a partir de  $\hat{y}_t^Q = \Xi_t y_{t-1}^Q + \frac{1}{3} \hat{y}_t$ , onde  $\Xi_t = 0$  para  $t$  correspondendo ao primeiro mês do trimestre e  $\Xi_t = 1$  para os demais. Dessa forma, a [Equação \(8\)](#) é mantida no terceiro mês de cada trimestre. A inclusão da previsão do PIB no vetor de estado,  $\alpha_t' = (f_t, \hat{y}_t, \hat{y}_t^Q)$ , tem o objetivo de facilitar o cálculo.

$$\begin{bmatrix} x_t \\ y_t^Q \end{bmatrix} = \begin{bmatrix} \Lambda & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f_t \\ \hat{y}_t \\ y_t^Q \end{bmatrix} + \begin{bmatrix} \xi_t \\ \epsilon_t^Q \end{bmatrix} \quad (9)$$

$$\begin{bmatrix} I_r & 0 & 0 \\ -\beta' & 1 & 0 \\ 0 & -\frac{1}{3} & 1 \end{bmatrix} \begin{bmatrix} f_{t+1} \\ y_{t+1}^Q \\ \hat{y}_{t+1}^Q \end{bmatrix} = \begin{bmatrix} A_1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \Xi_{t+1} \end{bmatrix} \begin{bmatrix} f_t \\ \hat{y}_t \\ \hat{y}_t^Q \end{bmatrix} + \begin{bmatrix} \zeta_{t+1} \\ 0 \\ 0 \end{bmatrix} \quad (10)$$

Resumidamente, a estimação dos parâmetros do modelo  $\theta = (\Lambda, A_1, \dots, A_p, \beta, \Sigma_\xi, B, \sigma_\epsilon^2)$  é realizada da seguinte forma:  $\Lambda$  é estimado a partir da análise de componentes principais (PCA) estáticos aplicada a um subamostra balanceada de dados  $\{x_s\}_{s=1}^T$ , isso

também fornece estimativas de amostras para os fatores comuns. Esses últimos são utilizados para estimar a [Equação \(6\)](#) e a versão trimestral de [\(7\)](#) através de técnicas padrões de regressão. A matriz  $B$  é estimada por análise de componentes principais aplicada aos resíduos estimados  $\hat{\zeta}_t$ .<sup>2</sup>

### 3.3 FILTRO DE KALMAN

Na realização de previsões em tempo real, os conjuntos de dados geralmente contêm observações ausentes no final da amostra, devido a defasagem na publicação, além disso, o número de dados ausentes difere entre as séries, devido às diferentes datas de publicação de cada indicador. Para obter previsões eficientes do crescimento trimestral do PIB através de um conjunto de dados desbalanceado, o filtro e a suavização de Kalman podem ser aplicados as equações de espaço de estado.

O filtro de Kalman foi proposto por [Kalman \(1960\)](#), é um algoritmo de processamento de dados recursivo, cujo objetivo é estimar os estados de uma maneira ótima, de modo que o erro quadrático médio seja minimizado, seu funcionamento incorpora toda a informação que é fornecida para determinar a filtragem.

Dadas as equações de estado com apenas uma defasagem na equação de transição:

$$x_t = \Lambda f_t + \xi_t, \text{ onde } \xi_t \sim \mathbb{N}(0, \Sigma_\xi) \quad (11)$$

$$f_t = A f_{t-1} + \zeta_t \quad (12)$$

O filtro de Kalman propõe um método para obter um estimador ótimo do estado. Se supomos que  $\hat{f}_k$  é o estimador do estado no instante  $k$ , o filtro de Kalman procurará obter esse valor de maneira que minimize o erro quadrático médio, seja o erro:

$$e_k = f_k - \hat{f}_k \quad (13)$$

O erro quadrático é:

$$P_k = E\{e_k e_k'\} \quad (14)$$

Definindo  $w$  como a data de extração dos dados, há diferentes representações do filtro de Kalman, dependendo da data  $k$ , se  $k > w$  trata-se de uma previsão, utiliza-se os dados disponíveis para a previsão de um estado futuro, se  $k = w$  uma filtragem, o objetivo é a atualização do estado atual através dos dados disponíveis, se  $k < w$  a suavização, busca-se suavizar a série de dados através da informação contida em

<sup>2</sup> Para mais detalhes sobre o método de estimação ver [Giannone et al. \(2006\)](#)

toda a série, de forma *backward*, ou seja percorrendo desde o presente até o estado inicial.

A filtragem de  $\hat{f}_{k+1}$  é feita a partir do estado anterior e de um fator de correção. O algoritmo de Kalman é executado em dois estágios iterativos: previsão e correção ou atualização do estado.

A primeira etapa da previsão é estimar o estado com base na dinâmica do modelo:

$$\bar{f}_{k+1} = A\hat{f}_k + \zeta_k \quad (15)$$

Assim,  $\bar{f}_{k+1}$  é o valor mais atualizado para o estado com base na informação disponível. Com base nos resultados obtidos é analisado o erro quadrático:

$$\bar{P}_{k+1} = A P_k A' + E[\zeta_{k+1} \zeta_{k+1}'] \quad (16)$$

Com isso, é prosseguido para a correção, onde o valor do estado é estimado a partir do estado calculado na previsão e de uma correção que é função do erro:

$$\hat{f}_{k+1} = \bar{f}_{k+1} + K_{k+1}[x_{k+1} - \Lambda \bar{f}_{k+1}], \quad (17)$$

a segunda parte do lado direito da igualdade é o fator de correção. Com isso, é necessário o  $K_{k+1}$  para obter o valor ótimo de  $\hat{f}_{k+1}$  tal que a matriz de covariância do erro seja mínima. O qual é:

$$K_{k+1} = \Lambda \bar{P}_{k+1} [\Lambda \bar{P}_{k+1} \Lambda' + E[\varepsilon_{k+1} \varepsilon_{k+1}']]^{-1}. \quad (18)$$

A atualização do erro quadrático fica como:

$$P_{k+1} = [I - K\Lambda] \bar{P}_{k+1}. \quad (19)$$

Dessa forma, a filtragem resulta em um novo estado utilizando toda a informação disponível e com o mínimo ruído.

A suavização de Kalman, pelo método de intervalo fixo, utiliza as medidas de média e variância encontrados no filtro de Kalman para suavizar toda a série, partindo da última observação até a primeira.

Tanto na filtragem quanto na suavização, após cada período de atualizações, o processo é repetido com a informação mais atualizada e as estimativas posteriores são utilizadas para previsão do novo estado. A recursividade é uma das características mais atraentes do Filtro de Kalman, resultando em implementações práticas e com baixo custo computacional para cada estimativa.

### 3.4 ABORDAGEM NÃO PARAMÉTRICA

Nessa seção será apresentada a metodologia não paramétrica, a qual será utilizada para a estimação do crescimento trimestral do PIB na equação *bridge*, análoga a [Equação \(7\)](#).

Segundo [Henderson e Parmeter \(2015\)](#) a maioria das pesquisas empíricas em economia ignora os benefícios potenciais dos métodos não paramétricos, os quais não assumem grandes hipóteses difíceis de satisfazer sobre a função de regressão, mas apenas suposições mínimas, tonando-os capazes de chegar mais próximos das distribuições reais dos parâmetros do modelo.

Dada a função de regressão  $m : \mathbb{R}^p \rightarrow \mathbb{R}$  não paramétrica <sup>3</sup>, é possível reescrevê-la como:

$$m(x) = E[Y|X = x] \quad (20)$$

$$= \int y f_{Y|X=x}(y) dy \quad (21)$$

$$= \frac{\int y f(x, y) dy}{f_X(x)} \quad (22)$$

Pode-se definir o objetivo de um modelo não paramétrico como encontrar o estimador  $\hat{m}$  de  $m$  que minimize a soma do erro quadrático (SEQ):

$$\sum_{i=1}^n (Y_i - \hat{m}(X_i))^2. \quad (23)$$

Sem assumir nenhuma forma particular para o verdadeiro  $m$ , faz-se necessária uma abordagem matemática alternativa. O primeiro passo é introduzir uma parametrização local, o que pode ser feito por uma expansão de Taylor de ordem  $\rho$ , para  $x$  próximo de  $X_i$ :

$$m(X_i) \approx m(x) + m'(x)(X_i - x) + \frac{m''(x)}{2}(X_i - x)^2 + \dots + \frac{m^{(\rho)}(x)}{\rho!}(X_i - x)^\rho. \quad (24)$$

Dessa forma, substituindo [Equação \(24\)](#) na [Equação \(23\)](#) tem-se:

$$\sum_{i=1}^n \left( Y_i - \sum_{j=0}^{\rho} \frac{m^{(j)}(x)}{j!} (X_i - x)^j \right)^2. \quad (25)$$

<sup>3</sup> Considerando a situação mais simples, um preditor contínuo.

Porém a resolução da [Equação \(25\)](#) ainda não é viável, pois depende de variáveis desconhecidas, a solução é definir  $\beta_j := \frac{m^{(j)}(x)}{j!}$  e transformar a equação em uma regressão linear onde os parâmetros desconhecidos são  $\beta = (\beta_0, \beta_1, \dots, \beta_\rho)'$ , assim:

$$\sum_{i=1}^n \left( Y_i - \sum_{j=0}^{\rho} \beta_j (X_i - x)^j \right)^2. \quad (26)$$

Com isso, estimativas para  $\beta$  automaticamente produzem as estimativas para  $m^{(j)}(x)$ . O passo final é mensurar a contribuição de cada observação  $(X_i, Y_i)$  para a estimação de  $m(x)$  de acordo com a proximidade de  $X_i$  com  $x$ , o que pode ser realizado através de *kernels*  $K$  com largura de banda  $h$ :

$$\hat{\beta}_h = \arg \min_{\beta \in \mathbb{R}^{\rho+1}} \sum_{i=1}^n \left( Y_i - \sum_{j=0}^{\rho} \beta_j (X_i - x)^j \right)^2 K_h(x - X_i). \quad (27)$$

Para resolução da [Equação \(27\)](#) se faz necessária a introdução da seguinte notação:

$$\mathbf{X} = \begin{pmatrix} 1 & X_1 - x & \cdots & (X_1 - x)^\rho \\ \vdots & \vdots & \ddots & \vdots \\ 1 & X_n - x & \cdots & (X_n - x)^\rho \end{pmatrix}_{n \times (\rho+1)}, \quad (28)$$

e

$$\mathbf{W} = \text{diag}(K_h(X_1 - x), \dots, K_h(X_n - x)), \quad \mathbf{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}_{n \times 1}. \quad (29)$$

Então pode-se expressar a [Equação \(27\)](#) como:

$$\hat{\beta}_h = \arg \min_{\beta \in \mathbb{R}^{\rho+1}} (\mathbf{Y} - \mathbf{X}\beta)' \mathbf{W} (\mathbf{Y} - \mathbf{X}\beta) \quad (30)$$

$$= (\mathbf{X}' \mathbf{W} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W} \mathbf{Y}. \quad (31)$$

Assim, a estimativa para  $m(x)$  é:

$$\hat{m}(x; \rho, h) = \hat{\beta}_{h,0} \quad (32)$$

$$= e_1' (\mathbf{X}' \mathbf{W} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W} \mathbf{Y} \quad (33)$$

$$= \sum_{i=1}^n W_i^\rho(x) Y_i, \quad (34)$$

onde:

$$W_i^p(x) = e_i'(X'WX)^{-1}X'W e_i, \quad (35)$$

e  $e_i$  é o  $i^{\text{o}}$  vetor canônico.

O estimador é uma combinação linear ponderada das respostas de cada observação. Dois casos merecem atenção especial e são testados empiricamente nesta dissertação:

- $p = 0$  é o estimador local constante ou Nadaraya–Watson. Nessa situação o estimador tem a seguinte ponderação:

$$W_i^0(x) = \frac{K_h(x - X_i)}{\sum_{j=1}^n K_h(x - X_j)}. \quad (36)$$

- $p = 1$  é o estimador local linear, com a seguinte ponderação:

$$W_i^1(x) = \frac{1}{n} \frac{\hat{s}_2(x; h) - \hat{s}_1(x; h)(X_i - x)}{\hat{s}_2(x; h)\hat{s}_0(x; h)} - \hat{s}_2(x; h)^2 K_h(x - X_i), \quad (37)$$

onde  $\hat{s}_r(x; h) = \frac{1}{n} \sum_{i=1}^n (X_i - x)^r K_h(x - X_i)$ .

### 3.4.1 Regressão Multivariada

Nessa subseção as metodologias de estimação não paramétrica são extendidas para abarcar os casos onde há múltiplas variáveis explicativas  $X_1, \dots, X_r$ .

Para extender o estimador não paramétrico  $\hat{m}(\cdot; \rho, h)$  para lidar com  $r$  preditores<sup>4</sup>, é necessário trabalhar com os produtos dos *kernels* para evitar aumentar o número de larguras de bandas de suavização  $h$ , dessa forma:

- Estimador local constante:

$$\hat{m}(x; 0, h) = \sum_{i=1}^n \frac{K_h(x - X_i)}{\sum_{i=1}^n K_h(x - X_i)} Y_i = \sum_{i=1}^n W_i^0(x) Y_i, \quad (38)$$

onde

$$K_h(x - X_i) = K_{h_1}(x_1 - X_{i1}) \cdots K_{h_r}(x_r - X_{ir}), \quad (39)$$

<sup>4</sup> Aqui são focados apenas nos casos  $\rho = 0$  e  $\rho = 1$ .

$$W_i^0(x) = \frac{K_h(x - X_i)}{\sum_{i=1}^n K_h(x - X_i)}. \quad (40)$$

- Estimador local linear: considerando a expansão de Taylor, tem-se que:

$$\hat{\beta}_h = \arg \min_{\beta \in \mathbb{R}^{p+1}} \sum_{i=1}^n (Y_i - \beta'(1, (X_i - x)'))^2 K_h(x - X_i), \quad (41)$$

novamente são necessárias as notações:

$$\mathbf{X} = \begin{pmatrix} 1 & (X_1 - x)' \\ \vdots & \vdots \\ 1 & (X_n - x)' \end{pmatrix}_{n \times (p+1)}, \quad (42)$$

$$\mathbf{W} = \text{diag}(K_h(X_1 - x), \dots, K_h(X_n - x)). \quad (43)$$

Assim, a estimativa para  $m(x)$  é:

$$\hat{m}(x; 1, h) = \hat{\beta}_{h,0} \quad (44)$$

$$= \mathbf{e}'_1 (\mathbf{X}' \mathbf{W} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W} \mathbf{Y} \quad (45)$$

$$= \sum_{i=1}^n W_i^p(x) Y_i, \quad (46)$$

onde:

$$W_i^1(x) = \mathbf{e}'_1 (\mathbf{X}' \mathbf{W} \mathbf{X})^{-1} \mathbf{X}' \mathbf{W} \mathbf{e}_i. \quad (47)$$

Cabe ressaltar que a escolha do tipo de *Kernel*  $K$  e largura de banda  $h$  tem alto impacto sobre os resultados do modelo e a necessidade de capacidade computacional.

Existem diversos tipos de *Kernel* que podem ser utilizados, os mais comuns na literatura, segundo [Henderson e Parmeter \(2015\)](#), são apresentados na [Tabela 1](#).

Nesta dissertação será utilizado o *Kernel* Epanechnikov, segundo [Henderson e Parmeter \(2015\)](#) ele apresenta boa eficiência na estimação do modelo e demanda baixa capacidade computacional, o que combina com as necessidades de atualização constate do Nowcasting.

A largura de banda  $h$  é escolhida conforme critério de informação *cross-validation*:

$$CV(\mathbf{h}) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{m}_{-i}(\mathbf{X}_i; \rho, \mathbf{h}))^2, \quad (48)$$

Tabela 1 – *Kernels* comuns

<i>Kernel</i>	Fórmula
Uniforme	$k_0(\psi) = \frac{1}{2} 1\{ \psi  \leq 1\}$
Epanechnikov	$k_1(\psi) = \frac{3}{4}(1 - \psi^2) 1\{ \psi  \leq 1\}$
Biweight	$k_2(\psi) = \frac{15}{16}(1 - \psi^2)^2 1\{ \psi  \leq 1\}$
Triweight	$k_3(\psi) = \frac{35}{32}(1 - \psi^2)^3 1\{ \psi  \leq 1\}$
Gaussian	$k_\phi(\psi) = \frac{1}{\sqrt{2\pi}} e^{-(1/2)\psi^2}$

Fonte – Henderson e Parmeter (2015)

$$\hat{h}_{CV} = \arg \min_{h_1, \dots, h_r > 0} CV(h) \quad (49)$$

## 4 DADOS

Nesta dissertação foram utilizadas 114 séries temporais, onde o crescimento trimestral do PIB (trimestre contra trimestre do ano anterior) é dependente de 113 variáveis explicativas mensais. A escolha das variáveis foi realizada seguindo a literatura sobre Nowcastings para o Brasil (Liu *et al.* (2011), Dahlhaus *et al.* (2015), Bragoli *et al.* (2014), Kagohara (2015), Pedro Montero Mattos (2017) e Gomes (2018)), através dela foram escolhidas variáveis reais e financeiras importantes para o crescimento econômico, além disso, nesta dissertação foram acrescentadas variáveis relativas a estabilidade financeira e mais algumas de lançamento mais recente da indústria, vendas, agropecuária <sup>1</sup> e o IBC-Br, as quais ainda não haviam sido utilizadas na literatura citada.

As variáveis foram classificadas em doze categorias, a [Tabela 2](#) apresenta as quantidades de variáveis em cada uma delas:

Tabela 2 – Categorias das variáveis explicativas

Categoria	Quantidade
Agropecuária	4
Energia	4
Estabilidade financeira	20
Financeiras	8
Indústria	10
Internacional	24
Monetários	4
Pesquisas	10
Preços	8
Setor público	5
Trabalho	7
Vendas	9
<b>Total</b>	<b>113</b>

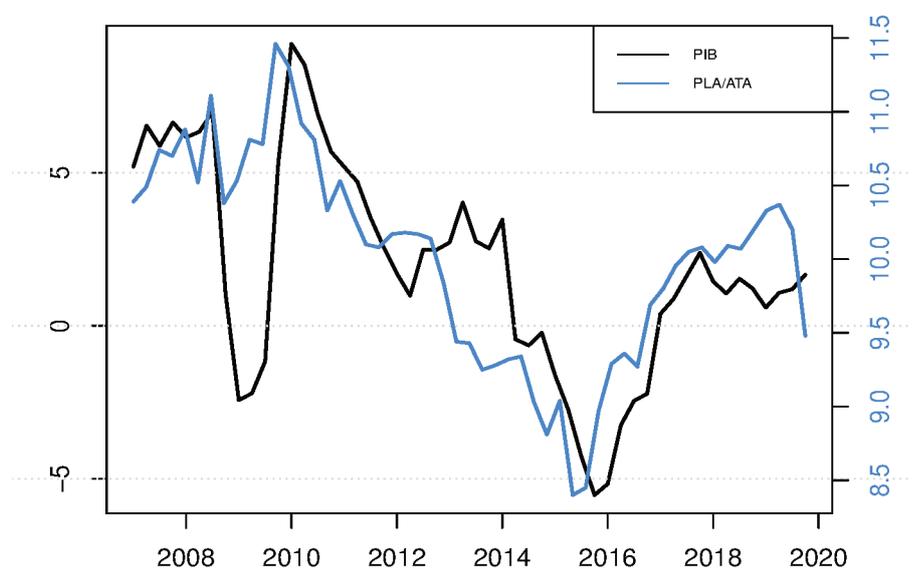
Fonte – Elaboração própria

- Agropecuária: IC-Br (índice de preços de produtos agropecuários), área plantada e área colhida gerais, e produção de cereais, leguminosas e oleaginosas;
- Energia: Consumo de energia em GW/h em diferentes setores da economia;
- Estabilidade financeira: Indicadores sobre saldo de crédito, inadimplência, comprometimento de renda das famílias, Índice de Basiléia e resultados contábeis dos bancos;

<sup>1</sup> As quais são as variáveis nessas categorias com início posterior ao ano 2000, ver [Apêndice A](#)

- Financeiros: Indicadores sobre a Ibovespa, taxas referenciais de swaps DI (30 a 360 dias) e taxa de juros CDI anualizada;
- Indústria: Produção em diferentes tipos de indústria e índice de utilização da capacidade instalada;
- Internacional: Resultados da balança de pagamentos brasileira, taxa de câmbio, índices das principais bolsas de valores mundiais, preços de commodities, importação de países selecionados e taxa de inflação EUA;
- Monetários: Indicadores da base monetária e taxa de juros SELIC;
- Pesquisas: PIB mensal interpolado, IBC-Br, índices de confiança, indicador composto OCDE e média da pesquisa FOCUS (horizonte mais curto);
- Preços: Índices de preços;
- Setor público: Dívida, receitas tributárias e resultado primário do governo;
- Trabalho: Índice de emprego formal, massa salarial e saldos de movimentações de empregos por setor;
- Vendas: Vendas em diferentes tipos de comércio.

Figura 4 – Crescimento trimestral do PIB x Patrimônio Líquido/Ativos



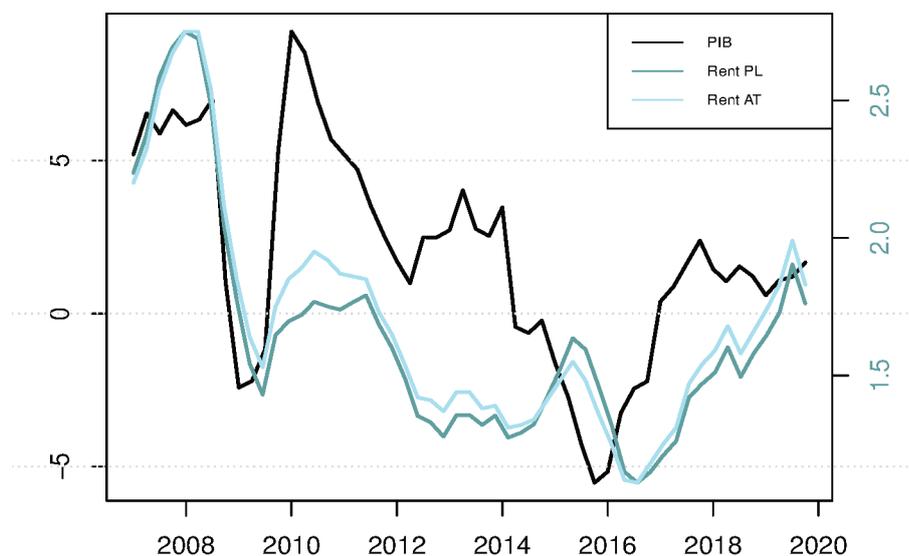
Fonte – Elaboração Própria

Tratando-se das variáveis de estabilidade financeira, é possível observar uma grande correlação ( $0.72^2$ ) entre o crescimento trimestral do PIB e a relação de patrimônio líquido e ativos dos bancos (PLA/ATA), veja [Figura 4](#).

<sup>2</sup> Quanto mais próximo de 1 ou -1, maior a correlação

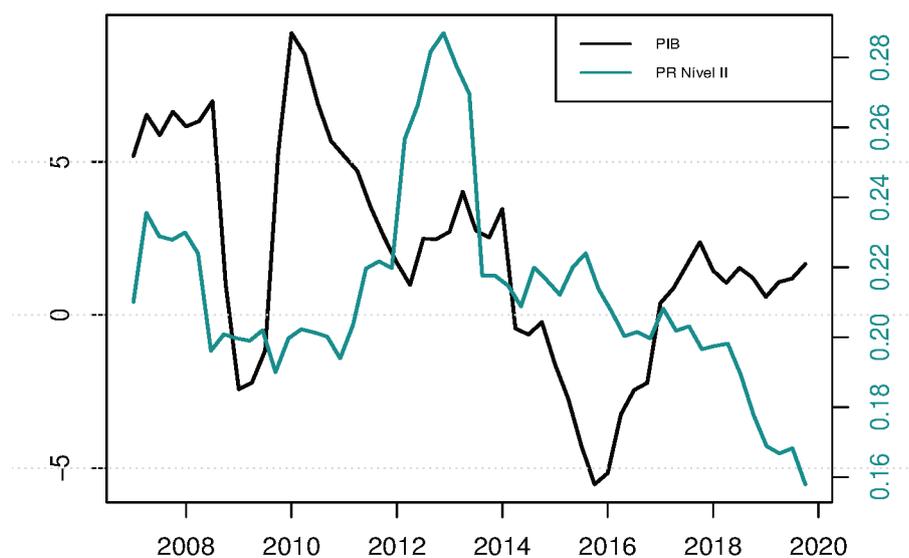
Além disso, as rentabilidades dos bancos também apresentam correlação com o PIB (rentabilidade sobre patrimônio líquido (Rent PL)= 0,56 e rentabilidade sobre ativos (Rent AT)= 0,64), por outro lado a participação de ativos do nível 2 (de maior risco) não demonstra correlação com o PIB (0,09), ver [Figura 5](#) e [Figura 6](#).

Figura 5 – Crescimento trimestral do PIB x Rentabilidade dos bancos



Fonte – Elaboração Própria

Figura 6 – Crescimento trimestral do PIB x participação % do Ativos Nível II



Fonte – Elaboração Própria

Contrariamente ao apresentado na [Seção 2.2](#), não é possível observar aumento da exposição dos bancos em momentos de crescimento econômico, esse é acompa-

nhado por queda da alavancagem, além disso, não há uma relação clara com a composição da carteira em ativos de maior risco. Outro aspecto importante, é que após a crise financeira de 2008 a rentabilidade sofreu uma queda significativa, demonstrando o impacto da queda da taxa de juros de vários países em resposta à crise.

Para tornar possível a utilização de variáveis mais recentes, sem a simulação de dados antes do início de algumas séries, foi necessário trabalhar com um conjunto de dados com séries temporais relativamente pequenas, vários dos indicadores sobre estabilidade têm seu início apenas no ano 2000 e indicadores mensais sobre a agropecuária no terceiro trimestre de 2006. Dessa forma, o período dos dados utilizados nesta pesquisa foi de setembro de 2006 até março de 2020; porém para tornar algumas séries estacionárias foram necessárias diferenciações anuais e mensais (esse procedimento resultou em melhores fatores na estimação DFM, e é procedimento comum na literatura apresentada na [Seção 2.1](#)), assim foram perdidas treze observações. Após isso, todas as variáveis do painel se tornaram estacionárias ao nível de 95%, foi utilizado o teste KPSS para o teste de estacionariedade, cujos resultados são apresentados no [Apêndice C](#).

Outros tratamentos necessários, foram o deflacionamento das séries com valores correntes em real pelo índice IPCA e em dólar pelo índice de inflação dos EUA, isso para trabalhar com impacto real das variáveis. Além disso, foram realizadas substituições dos valores não disponíveis e *outliers* por sua média móvel de dois períodos, seguindo metodologia proposta por [Giannone et al. \(2008\)](#).

Finalmente, devido a sensibilidade do modelo PCA a mudanças de escala, foi necessária a padronização das variáveis, o que foi realizado com a fórmula z-score:

$$x_{j_p} = \frac{x_j - \bar{x}_j}{s(x_j)}, \quad (50)$$

onde  $x_{j_p}$  é vetor da variável  $x_j$  padronizado, com a subtração da sua média e divisão por seu desvio padrão. Dessa forma,  $x_{j_p}$  tem média = 0 e variância = 1.

A lista completa das variáveis utilizadas está disponível no [Apêndice A](#), tanto quanto detalhes sobre elas: fonte, tipo (unidade de medida), início da série, defasagem de publicação, necessidade de tratamento quanto a inflação e diferenciação. O [Apêndice B](#) apresenta algumas estatísticas descritivas das variáveis antes dos tratamentos.

O período outubro de 2007 até setembro de 2016 foi utilizado dentro da amostra, enquanto o período outubro de 2016 até março de 2020 foi utilizado fora da amostra. Como os diferentes indicadores não são contemporâneos em sua divulgação, foram simulados 42 conjuntos de dados com a informação disponível no primeiro dia de cada um dos meses fora da amostra, conforme defasagem média de divulgação apresentado no [Apêndice A](#). Da mesma forma, foram simulados quatorze conjuntos para o crescimento do PIB trimestral.

Todos os dados foram baixados no dia 20/04/2020, 75% dos dados foram baixados automaticamente com a utilização dos pacotes BETS ([Ferreira \*et al.\* \(2018\)](#)) e BatchGetSymbols ([Perlin \(2020\)](#)) do software R e da API Sidra do IBGE ([IBGE \(2020\)](#)), o restante dos dados foram baixados manualmente nas respectivas fontes de dados.

## 5 RESULTADOS

Para a estimação do modelo foi desenvolvido um algoritmo próprio no software R, no qual os pacotes *nowcasting* (Daiane Marcolino de Mattos *et al.* (2019)) e *np* (Hayfield e Racine (2008)) foram utilizados como base para seu desenvolvimento.

Para a especificação do modelo foi necessário definir a quantidade de fatores  $r$ , a quantidade de choques sobre os fatores  $q$  (o rank da matriz de covariância dos resíduos da equação de transição) e a quantidade de defasagens  $p$ . Para isso, foram utilizados critérios de informação, conforme Bai e Ng (2002) e Bai e Ng (2007). A especificação que demonstrou melhores resultados foi  $r = 3$ ,  $q = 2$  e  $p = 1$ , em todos os 42 conjuntos de dados essa quantidade de fatores explicou de 40,2% até 45,8% da covariância do painel de dados.

Embora essa pesquisa tenha gerado 42 estimativas distintas, uma para cada conjunto de dados simulados, apenas serão abordados aqui os resultados obtidos no período 01/03/2020, devido a esse ser o período com o maior conjunto de dados. Não obstante, os resultados das demais estimativas não diferem significativamente, sobretudo sobre o peso das variáveis na composição dos fatores.

A Tabela 3 demonstra os pesos médios das classes de variáveis na construção dos três fatores, enquanto as figuras (7), (8) e (9) os pesos das variáveis em cada um deles.

Tabela 3 – Peso médio das variáveis nos fatores - Março/2020

Categoria	Peso (%)
Agropecuária	1,65%
Energia	2,39%
Estabilidade financeira	8,66%
Financeiras	12,48%
Indústria	8,47%
Internacional	19,17%
Monetários	2,34%
Pesquisas	15,68%
Preços	4,17%
Setor público	2,27%
Trabalho	5,76%
Vendas	16,95%
<b>Total</b>	<b>100%</b>

Fonte – Elaboração própria

Com base nas informações dispostas, é possível perceber que as variáveis com maior impacto no painel de dados são das categorias Internacional, Vendas, Pesquisas, Financeiras e Estabilidade financeira, por ordem de importância. Esse resultado vai ao

encontro da literatura apresentada na [Seção 2.1](#), qual verificou grande impacto desses indicadores para a previsão de diferentes variáveis econômicas em diversos países.

Históricamente o Brasil é um país muito dependente da exportação, sobretudo de commodities, sensível as movimentações da economia mundial, as políticas e crises externas. O impacto da categoria Internacional, verificado nessa pesquisa, é algo que confirma esse cenário. Além disso, resultado similar já foi relatado por [Liu et al. \(2011\)](#).

Não é surpresa a classe Vendas ocupar o segundo lugar, o varejo tem grandes impactos diretos e indiretos sobre vários setores da economia brasileira, além de ser indicativo direto da demanda nacional. Tal resultado é semelhante ao obtido por [Bragoli et al. \(2014\)](#).

A novidade aqui se mostra com a categoria Estabilidade financeira ocupando a quinta colocação, visto que as variáveis dessa categoria ainda são subexploradas na literatura sobre previsões de variáveis macroeconômicas brasileiras. A colocação obtida por essa categoria demonstra que a estabilidade financeira tem grande relação com diversas variáveis da economia, fato que corrobora com a importância da estabilidade financeira para o crescimento econômico, conforme descrito na [Seção 2.2](#).

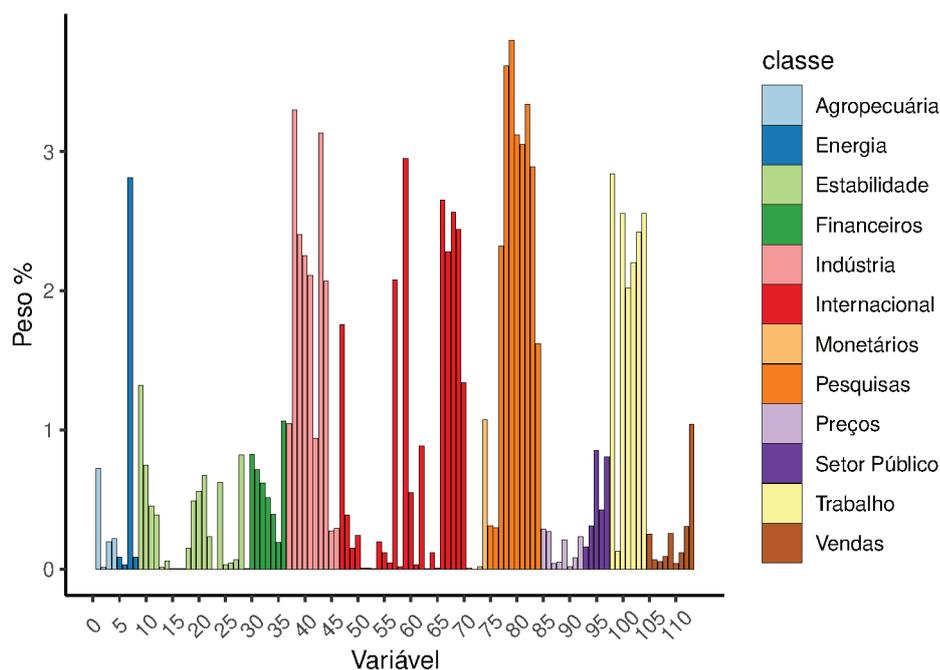
Tratando-se da categoria Estabilidade financeira, as variáveis que demonstraram maior impacto são o Índice de Basiléia, a inadimplência da carteira de crédito das instituições financeiras nacionais, índice de liquidez das instituições privadas nacionais e estrangeiras e o saldo de crédito. Tais variáveis detêm 60,42% do impacto total da classe.

A importância dessas variáveis, da categoria Estabilidade financeira, reforça a literatura da [Seção 2.2](#), sendo que o Índice de Basiléia mede a adequação de capital das instituições do sistema bancário, e é indicador essencial para mensuração de exposição ao risco das instituições bancárias; a inadimplência é um grande fator de choque, o qual é amplificado dependendo da alavancagem dos bancos; tanto a liquidez, quanto o saldo de crédito são fatores determinantes na reação dos bancos aos choques, além disso, eles podem indicar a espiral de liquidez, conforme [Brunnermeier e Sannikov \(2016b\)](#) e [Brunnermeier e Sannikov \(2016a\)](#).

No que tange o primeiro fator, pode-se perceber que diversas variáveis tem peso em sua formação, principalmente das categorias Pesquisas, Indústria, Monetários, Trabalho e Energia, ver [Figura 7](#). Arbitrariamente esse fator será chamado de “Fator Conjuntural”, pois traz consigo a relação entre distintas categorias. Além do mais, é interessante notar que esse relacionamento se faz entre variáveis a respeito da expectativa dos agentes econômicos (categoria Pesquisas) e as variáveis reais da economia brasileira e mundial.

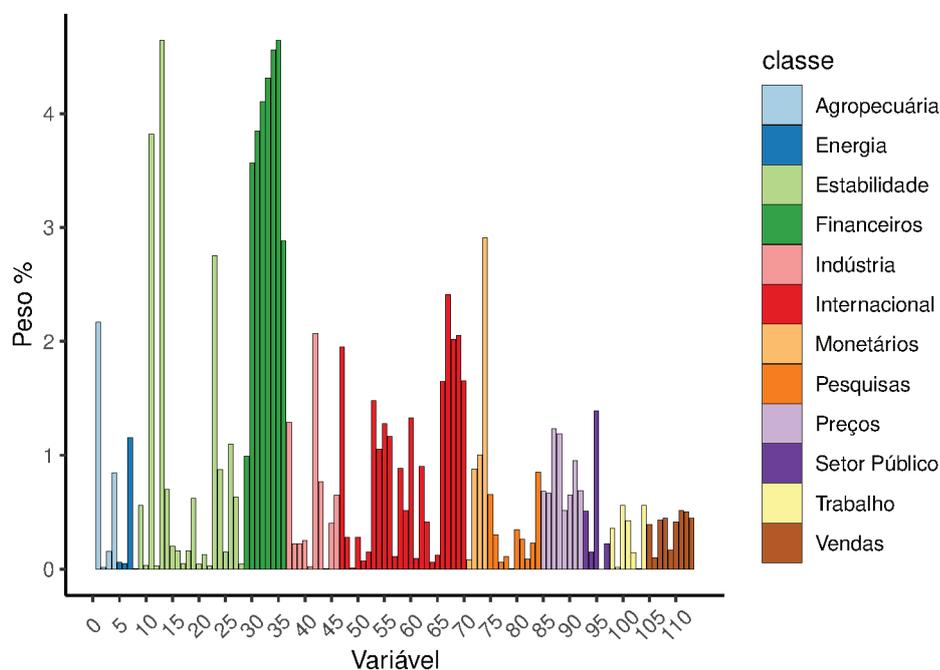
Já no segundo fator, [Figura 8](#), as variáveis das categorias Financeiras, Estabilidade financeira e Internacional se destacam, além da variável SELIC. Dessa forma, pode-se ver que esse fator explica melhor a dinâmica do mercado financeiro, levando

Figura 7 – Peso das variáveis no Fator 1 (Conjuntural) - Março/2020



Fonte – Elaboração Própria

Figura 8 – Peso das variáveis no Fator 2 (Mercado financeiro) - Março/2020

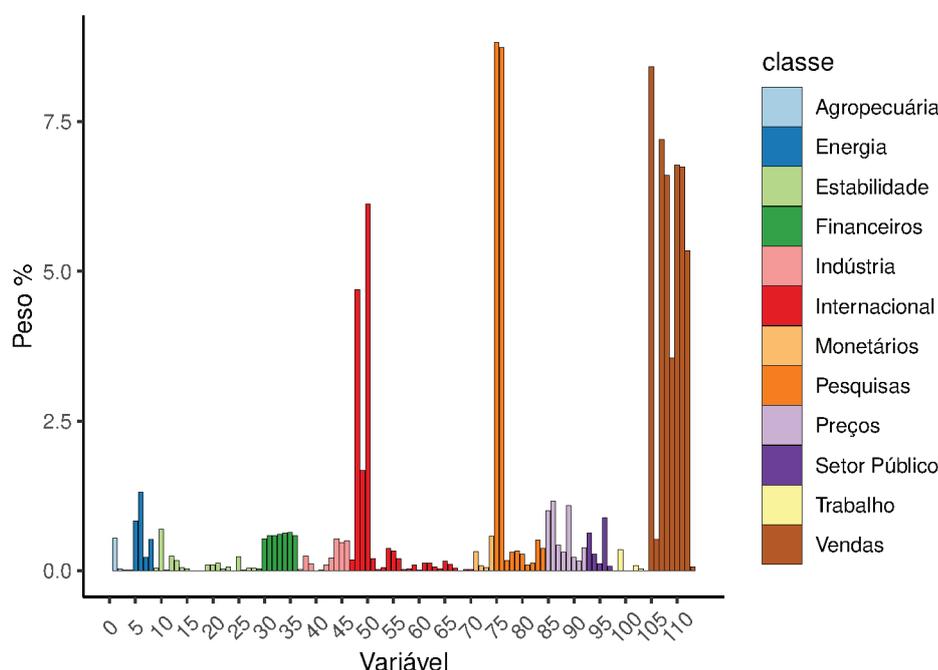


Fonte – Elaboração Própria

em consideração diversos aspectos; o referido fator consegue traçar o relacionamento entre o mercado financeiro brasileiro, a principal variável de política econômica do Bacen, as principais bolsas de valores do mundo e os preços de commodities mundiais.

Devido a essas características, será chamado de “Fator Mercado Financeiro”.

Figura 9 – Peso das variáveis no Fator 3 (Demanda) - Março/2020



Fonte – Elaboração Própria

Por fim, o terceiro fator, [Figura 9](#), é o fator com menos variáveis relevantes para sua construção, ele é composto pela relação entre o “PIB mensal”, ou seja, as pesquisas de PIB mensal interpolado e índice IBC-Br, variáveis sobre vendas e importação brasileira. Intuitivamente pode-se perceber que esse fator demonstra a demanda do Brasil, assim será chamado de “Fator Demanda”.

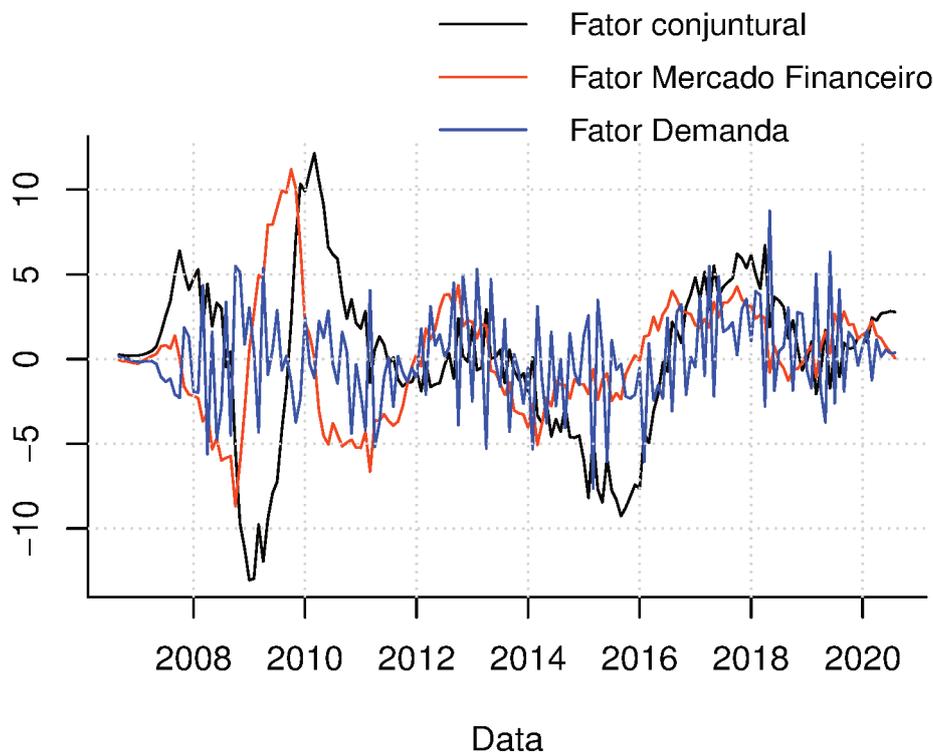
Isto posto, pode-se observar o comportamento temporal de ambos os 3 fatores, no período de 2007 a 2020 na [Figura 10](#).

Os fatores estimados através do DFM e filtro de Kalman foram utilizados para estimar o crescimento trimestral do PIB brasileiro, utilizando metodologia paramétrica (modelo MQO, o qual será chamado apenas de Now) e não paramétricas, com estimador local constante ( $Now_{lc}$ ) e local linear ( $Now_{ll}$ ). Para isso, nas estimações não paramétricas foi utilizado o *Kernel Epanechnikov*, com largura de banda ótima selecionada pela minimização do erro quadrático da *Cross-Validation*.

Os resultados médios dos modelos dentro da amostra são apresentados na [Tabela 4](#), onde  $R^2$  representa o poder de explicação dos modelos, e o erro quadrático médio (EQM) é uma das principais medidas para mensurar o erro. Embora todos os modelos apresentem bons resultados, é possível observar que os modelos não paramétricos, sobretudo o  $Now_{lc}$ , são superiores, apresentam  $R^2$  maiores e menores erros.

Destarte, o ajuste dos valores estimados dentro da amostra, com o modelo

Figura 10 – Fatores estimados - 2007 a 2020



Fonte – Elaboração Própria

Tabela 4 – Resultados médios dentro da amostra

Modelo	$R^2$	EQM
Now	0,660	4,662
Now <sub>IC</sub>	0,974	0,360
Now <sub>II</sub>	0,946	0,742

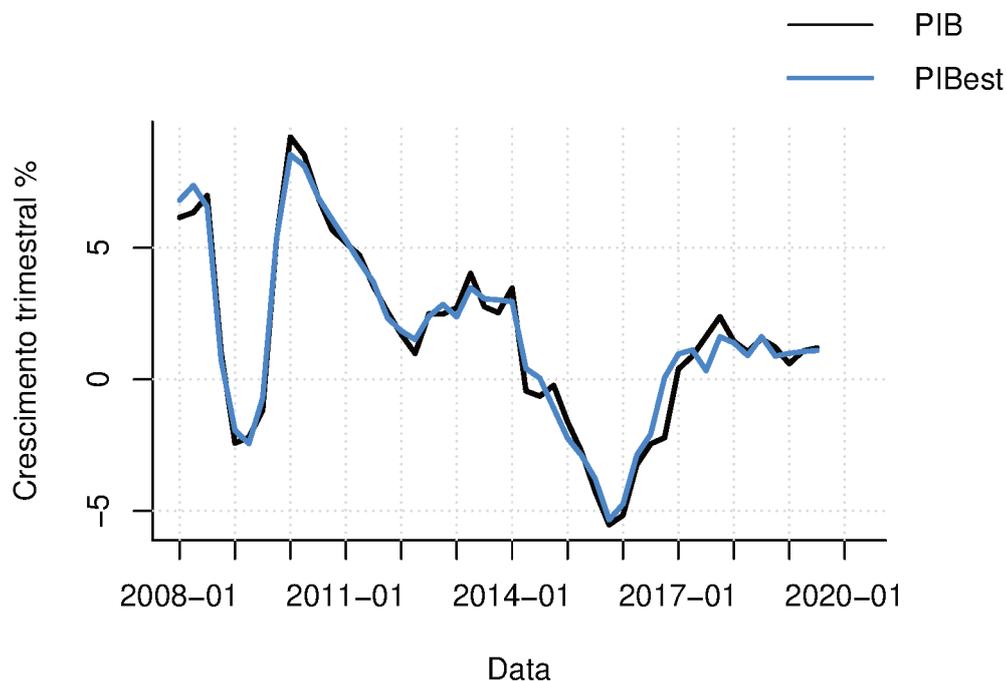
Fonte – Elaboração própria

Now<sub>IC</sub>, pode ser observado na [Figura 11](#). Ademais, cabe ressaltar que todos os 42 modelos estimados se mostraram significativos, com resíduos estacionários e com distribuição normal, segundo os testes KPSS e Jarque Bera, respectivamente.

Tratando-se do comportamento temporal dos coeficientes estimados nos modelos não paramétricos, percebe-se que o tipo de estimador possui grande impacto, os coeficientes estimados em cada um dos modelos têm comportamentos muito diversos; ver as figuras (12) e (13). Para ambos foi utilizado modelo bootstrap com 100 iterações e nível de confiança em 95%.

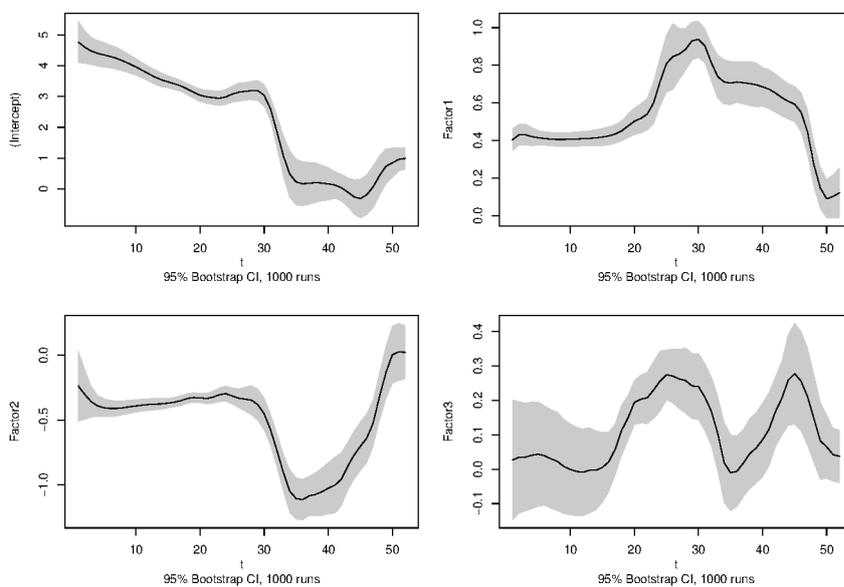
Dado o exposto, pode-se perceber que enquanto os parâmetros do modelo Now<sub>II</sub> têm comportamento linear, os parâmetros do Now<sub>IC</sub> são mais dinâmicos. Outro ponto relevante, é que os parâmetros desse último têm intervalos de confiança muito

Figura 11 – PIB estimado dentro da amostra -  $Now_{IC}$  (Março/2020)



Fonte – Elaboração Própria

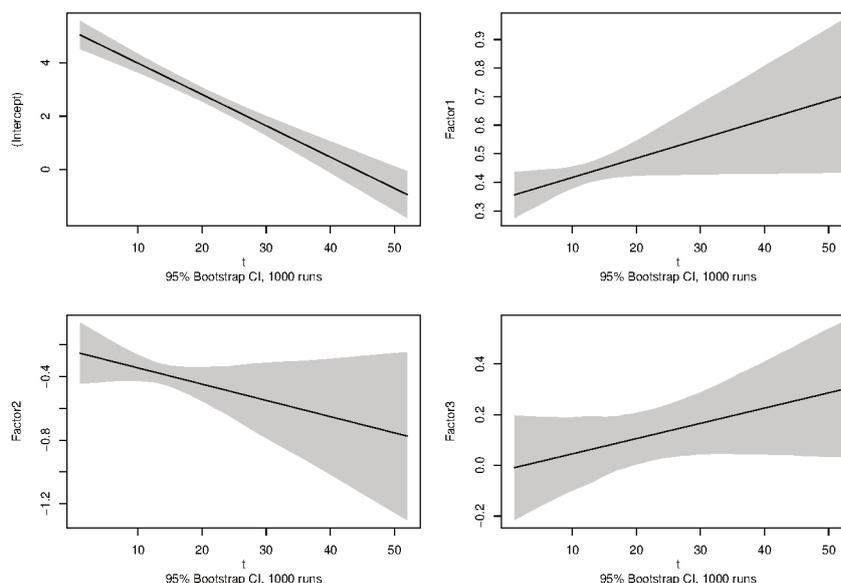
Figura 12 – Comportamento dos parâmetros no modelo  $Now_{IC}$



Fonte – Elaboração Própria

mais comportados, o que traz resultados mais confiáveis, tanto para estimações dentro de amostra, quanto fora dela.

Finalmente, mesmo nos parâmetros do  $Now_{II}$  há apenas 15% de probabilidade

Figura 13 – Comportamento dos parâmetros no modelo Now<sub>II</sub>

Fonte – Elaboração Própria

de distribuição normal (pelo teste Jarque Bera), tal resultado indica que a imposição da distribuição normal, como é o caso do modelo paramétrico, pode gerar resultados pouco realísticos em relação aos coeficientes.

## 5.1 COMPARAÇÃO DE PREVISÕES

Nesta seção são comparados os erros de previsão dos modelos Nowcasting apresentados anteriormente, além de dois *benchmarks*: a média da pesquisa FOCUS e um modelo SARIMA(0,1,1)(0,0,1)[4]. A pesquisa FOCUS consiste em projeções de especialistas do mercado enviadas ao Banco Central; além de ser uma pesquisa amplamente utilizada no Brasil, ela também serve como uma *proxy* para a combinação de diversos modelos utilizados pelos especialistas. Com o modelo SARIMA pretende-se a comparação dos Nowcastings com um modelo da classe ARIMA, metodologia que é comum para projeção de séries temporais, ademais, a especificação foi escolhida através de critério de informação.

O período utilizado fora da amostra vai de Outubro de 2016 até Março de 2020, o que totaliza 42 conjuntos simulados. Cada um dos conjuntos possui a informação disponível no primeiro dia de cada mês; o primeiro conjunto contém dados disponíveis entre 01/10/2007 e 01/10/2016, enquanto o último entre 01/10/2007 até 01/03/2020.

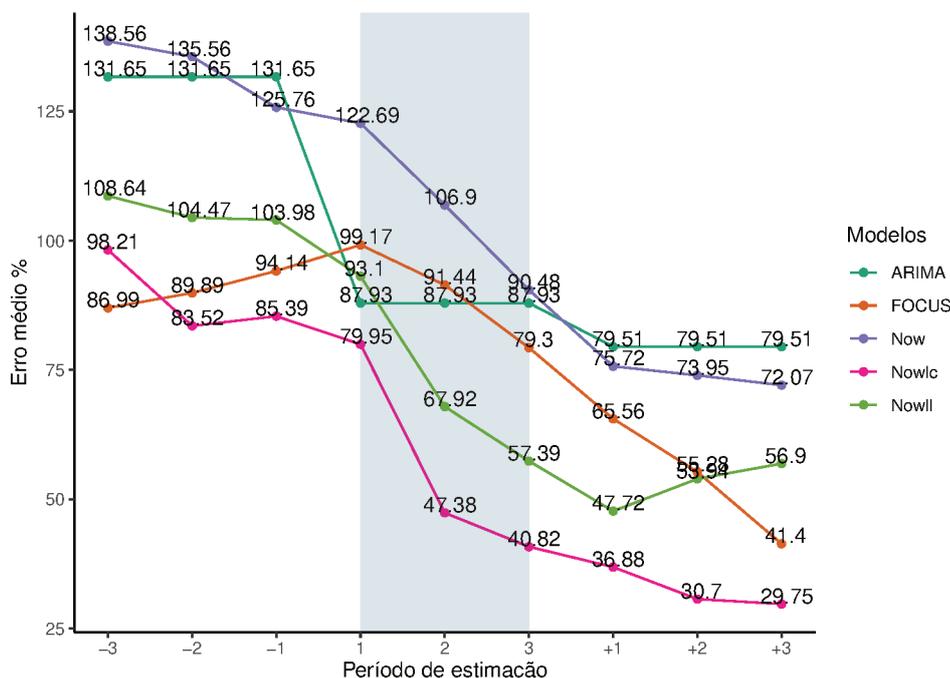
Por meio dos fatores gerados com cada um dos conjuntos de dados, foram projetados 12 trimestres, de 2017 até 2019. Cada trimestre foi estimado em nove períodos, partindo de três meses antes da realização do trimestre de referência (-3) até três meses depois (+3), mês em que é divulgado o PIB trimestral. A atualização

das previsões dos Nowcastings é realizada mensalmente, incorporando a informação disponibilizada até o fim do mês anterior.

A Figura 14 apresenta a comparação da média percentual absoluta dos erros (MAPE) de cada um dos modelos, a qual pode ser definida como:

$$MAPE = \frac{\sum_{t=1}^T |\hat{e}_t / Y_t|}{T} \quad (51)$$

Figura 14 – Erro médio (%)



Fonte – Elaboração Própria

Conforme literatura apresentada na Seção 2.1, é possível observar que a qualidade das previsões dos modelos Nowcasting, tanto quanto dos demais, melhoram conforme mais informações estão disponíveis, além disso, nos períodos dentro do trimestre de referência os modelos Nowcastings apresentam ganhos de eficiência maiores do que os benchmarks.

No período -3 as previsões dos modelos Nowcasting apresentam os piores resultados, porém já no -2 as previsões do Now<sub>lc</sub> são significativamente melhores que as demais e essa vantagem se mantém até o último período. Tratando-se do Now<sub>ll</sub>, esse demonstra resultados superiores aos benchmarks a partir do período 2, porém ele sofre queda de performance nos dois últimos períodos de estimação.

Pode-se observar que o modelo Now paramétrico obteve o pior erro entre todos os modelos, ele gerou previsões piores do que o SARIMA na maioria dos períodos de estimação. O Now apresenta uma diferença superior a 42 pontos percentuais em relação ao campeão (Now<sub>lc</sub>) no último período de estimação.

Tal resultado demonstra o poder preditivo das técnicas não paramétricas, além de obterem distribuições mais realistas sobre os coeficientes da equação *bridge*; os Nowcastings não paramétricos (principalmente o  $Now_{IC}$ ) obtiveram previsões com erros percentuais iguais ou menores aos benchmarkings na maioria dos períodos de estimação.

Na Tabela 5 é apresentada a comparação do erro quadrático médio (EQM) dos modelos Nowcasting e do principal benchmarking, a pesquisa FOCUS. Pode-se perceber que os EQMs seguem um comportamento similar ao MAPE, novamente os modelos não paramétricos se mostram superiores ao modelo paramétrico em todos os períodos de estimação, exceto o último onde o  $Now_{II}$  apresenta resultado inferior ao  $Now$ . Ainda, o modelo  $Now_{IC}$  se mostra superior aos demais na maioria dos períodos.

Tabela 5 – Comparação do erro quadrático médio

Período	$\overline{e^2}_{Now}$	$\overline{e^2}_{Now_{IC}}$	$\overline{e^2}_{Now_{II}}$	$\overline{e^2}_{FOCUS}$
-3	2,595	0,869	0,976	0,956
-2	2,243	0,688	1,076	0,721
-1	2,279	0,508	1,106	0,682
1	1,645	0,334	0,630	0,460
2	1,032	0,126	0,280	0,361
3	0,494	0,077	0,353	0,470
+1	0,304	0,137	0,170	0,181
+2	0,315	0,118	0,266	0,128
+3	0,282	0,101	0,346	0,023

Fonte – Elaboração própria

Entretanto, tratando-se do EQM há algumas diferenças em relação ao MAPE, que são relevantes. Enquanto a FOCUS aumenta sua eficiência de maneira monotônica, o  $Now_{IC}$  tem seu melhor resultado no período 3, enquanto no período +1 tem um resultado pior em relação ao anterior. Além disso, é possível perceber que no último período a FOCUS apresenta o melhor resultado. Em relação ao modelo  $Now_{II}$ , agora, esse consegue superar a FOCUS apenas nos períodos 2 até +1.

A Tabela 6 apresenta a variância do erro quadrático, ambos os modelos Nowcasting demonstram ineficiência nos primeiros períodos, com variâncias muito superiores a FOCUS. Novamente os modelos não paramétricos se mostram superiores ao  $Now$  na maioria dos períodos de estimação. A pesquisa FOCUS apresenta a menor variância na maioria dos períodos de estimação, porém tal resultado já era esperado, visto que essa trata-se da média de diversas previsões, que por sua vez podem ter sido construído com a média de vários modelos diferentes, dessa forma, naturalmente a variância é minimizada.

Este resultado aponta para a possibilidade de utilização das previsões dos modelos Nowcasting, combinadas a diferentes especificações e outras metodologias,

Tabela 6 – Comparação da variância do erro quadrático

Período	$s^2(e_{Now}^2)$	$s^2(e_{Now_{IC}}^2)$	$s^2(e_{Now_{II}}^2)$	$s^2(e_{FOCUS}^2)$
-3	5,402	3,975	4,459	0,922
-2	4,040	1,669	2,150	0,850
-1	3,090	0,818	1,243	0,893
1	2,118	0,824	0,610	0,976
2	1,144	0,127	0,683	0,699
3	0,710	0,729	1,094	0,328
+1	0,386	0,660	0,820	0,300
+2	0,335	0,161	0,712	0,219
+3	0,327	0,138	0,846	0,130

Fonte – Elaboração própria

afim de minimizar a variância e obter previsões mais eficazes.

Como último teste para as previsões, foi realizado o teste Diebold-Mariano (DM) com a hipótese nula de igualdade entre os modelos e com hipótese alternativa de superioridade. O teste de Diebold-Mariano compara as previsões de diferentes modelos, ele é baseado na seguinte função perda:

$$d_t = L(\hat{e}_t^1) - L(\hat{e}_t^2), \quad (52)$$

onde  $e_t^1$  são os erros no período  $t$  do modelo 1 e  $e_t^2$  do modelo 2.

Dessa forma, a hipótese nula é:

$$H_0 = E[d_t] = 0. \quad (53)$$

A estatística do teste DM é:

$$S = \frac{\bar{d}}{(\widehat{avar}(\bar{d}))^{1/2}} = \frac{\bar{d}}{(\widehat{LRV}_{\bar{d}})^{1/2}}, \quad (54)$$

onde:

$$\widehat{LRV}_{\bar{d}} = \tau_0 + 2 \sum_{j=1}^{\infty} \tau_j, \tau_j = cov(d_t, d_{t-j}). \quad (55)$$

$\widehat{LRV}_{\bar{d}}$  é uma estimativa da variância assintótica de  $\sqrt{T}\bar{d}$ . Sob a hipótese nula de acurácia preditiva:

$$S \sim N(0, 1), \quad (56)$$

logo rejeita-se a hipótese nula no nível de 5% se  $|S| > 1,96$ .

Como no teste DM é possível a comparação de apenas dois modelos, será apresentada apenas a comparação do modelo campeão nos testes anteriores:  $Now_{IC}$ , com o principal benchmarking: pesquisa FOCUS. A [Tabela 7](#) apresenta os resultados dos valores  $p$  do teste DM.

Tabela 7 – Valores  $p$  Teste Diebold-Mariano

Período	$Now_{IC} \approx FOCUS$	$Now_{IC} > FOCUS$
-3	57,63%	28,81%
-2	99,83%	49,91%
-1	82,10%	58,95%
1	13,35%	93,33%
2	4,77%	97,62%
3	62,88%	68,56%
+1	94,60%	47,30%
+2	73,07%	63,47%
+3	80,75%	40,37%

Fonte – Elaboração própria

Enquanto os testes anteriores apresentam a superioridade do  $Now_{IC}$  sobre a FOCUS na maioria dos períodos estimados, no teste DM, apenas nos períodos 1 a 3 isso ocorre, nos demais períodos o teste aponta para a igualdade dos resultados. De qualquer forma, pode-se concluir que o  $Now_{IC}$  apresenta resultados relativamente iguais ou superiores a pesquisa FOCUS em todos os períodos de estimação.

Com base nos resultados de MAPE, EQM e teste DM é possível concluir que os modelos Nowcasting não paramétricos, principalmente o  $Now_{IC}$  possuem bom desempenho preditivo, igualando ou até superando a média da pesquisa FOCUS em todos os períodos de estimação, onde são apresentados menores erros de previsão. A alta variância dos modelos nos períodos anteriores ao trimestre de referência, ressalta o baixo desempenho deles para projeções com horizontes mais longos, dessa forma, pode-se obter melhores previsões por intermédio da combinação das projeções de modelos Nowcasting com diferentes especificações, ou com outros tipos de modelos possivelmente destinados à análise de séries temporais.

Mesmo trabalhando com séries temporais relativamente pequenas e com dados bem comportados, foi possível obter bons resultados com a abordagem não paramétrica, já que estes modelos obtiveram resultados superiores à abordagem paramétrica em todos os períodos de estimação. Além disso, o  $Now_{IC}$  se mostrou similar ou superior a média da pesquisa FOCUS. Tal resultado demonstra o potencial da utilização de abordagem não paramétrica para previsões de variáveis macroeconômicas brasileiras, mesmo quando se dispõem de séries temporais pequenas. A abordagem não paramétrica não só se mostra como uma boa alternativa para metodologias de parâmetros variantes no tempo, mas também é capaz de encontrar distribuições mais adequadas

para os parâmetros estimados.

Cabe ressaltar, que a escolha do tipo de estimador dos modelos não paramétricos se mostrou muito relevante; em vários sentidos o  $Now_{lc}$  se mostrou superior ao  $Now_{ll}$ , obteve melhores comportamentos e intervalos de confiança para os coeficientes da equação *bridge*, maior  $R^2$  dentro da amostra, e menor erro de previsão fora dela. Além disso, nessa dissertação foi utilizado apenas o *Kernel Epanechnikov*, ou seja, o presente estudo não contempla todas as oportunidades de pesquisa contidas na literatura, em [Henderson e Parmeter \(2015\)](#) por exemplo, sobre a utilização de diferentes tipos de *Kernels*.

A comparação dos resultados preditivos do modelos dessa pesquisa com os resultados apresentados na literatura ([Seção 2.1](#)), não se mostra efetiva devido as diferenças de período utilizado fora da amostra, há diversos aspectos que podem tornar a previsão de um período mais/menos difícil. Entretanto, o resultado obtido com o  $Now_{lc}$  tem poder de previsão comparável aos obtidos por [Bragoli et al. \(2014\)](#), [Pedro Montero Mattos \(2017\)](#) e [Gomes \(2018\)](#) em relação ao principal benchmarking, ou seja, ambos superaram a média da pesquisa FOCUS, sobretudo nos meses posteriores ao trimestre de referência.

Conforme literatura apresentada na [Seção 2.1](#), a atualização das informações tem alto impacto sobre a assertividade das previsões, e o poder preditivo dos modelos Nowcasting aumentam consideravelmente ao final dos períodos.

Em todos os trimestre projetados diversas variáveis contribuíram para a atualização das projeções, ver [Apêndice D](#), porém é possível observar que algumas variáveis se destacam em todos os períodos de estimação; pode-se ver que as variáveis das categorias Financeiras, Pesquisas e Indústria têm um alto impacto, enquanto as variáveis das categorias Estabilidade Financeira, Vendas e Trabalho apresentam impactos pequenos a moderados.

Como esperado, variações na indústria e no mercado internacional têm alto impacto sobre o crescimento econômico. É interessante notar o impacto das pesquisas na atualização das previsões, tal resultado não só demonstra a qualidade técnica dessas, mas também a importância que as expectativas econômicas têm sobre a economia.

Por fim, cabe ressaltar, que as variáveis de Estabilidade Financeira não só são significativas para a construção dos fatores, mas também para a atualização das previsões, novamente corroborando com a literatura apresentada na [Seção 2.2](#), acerca do impacto da estabilidade financeira sobre o crescimento econômico, sua ligação com diversas variáveis da economia real, e a necessidade de monitoramento das variáveis ligadas a estabilidade.

## 6 CONCLUSÃO

Nessa pesquisa foram estimados modelos Nowcastings, utilizando 113 variáveis mensais para explicar o crescimento trimestral do PIB, conforme metodologia proposta por Bańbura e Rünstler (2007), tal metodologia utiliza modelo de fatores dinâmicos (DFM) e atualização por filtro de Kalman. Adicionalmente a isso, na equação *bridge* foram utilizadas metodologias paramétricas e não paramétricas.

Além dos indicadores comumente utilizados em previsões de variáveis brasileiras, também foram utilizados indicadores sobre estabilidade financeira, visto o impacto e capacidade de ampliação de choques que o sistema financeiro tem sobre a economia real, o qual é amplamente abordado na literatura (ver [Seção 2.2](#)). Porém o custo da utilização dessas variáveis, além de outras variáveis das demais categorias, foi trabalhar com um painel de dados com séries históricas relativamente menores, 2007 até 2020.

Foram simulados 42 conjuntos de dados, compreendendo o período de Outubro de 2007 até Março de 2020, com os dados disponíveis no primeiro dia de cada mês, conforme defasagem média para a publicação de cada indicador. Com esses conjuntos, por intermédio da metodologia DFM foi possível reduzir as 113 variáveis explicativas a três fatores que explicaram de 40,2% à 45,8% da dinâmica de todo o painel de dados. Esses três fatores foram chamados arbitrariamente de “Fator Conjuntural”, “Fator Mercado Financeiro” e “Fator Demanda”, devido as variáveis mais importantes na construção de cada um destes.

As variáveis mais importantes na composição dos três fatores pertencem as categorias: Internacional, Vendas, Pesquisas, Financeiras e Estabilidade Financeira, por ordem de importância.

A categoria Estabilidade Financeira teve um peso de 8,66% na composição dos fatores, o fato dela ter sido a quinta categoria mais importante, dentre doze categorias, demonstra que a estabilidade financeira tem grande relação com diversas variáveis da economia, fato que corrobora com a importância da estabilidade descrita na literatura. Dentre as variáveis mais importantes na categoria estão o Índice de Basileia, a inadimplência da carteira de crédito das instituições financeiras nacionais, o índice de liquidez das instituições privadas nacionais e estrangeiras e o saldo de crédito. Tais variáveis detiveram 60,42% do impacto total da categoria.

Foram projetados doze trimestres do crescimento trimestral do PIB fora da amostra, primeiro trimestre de 2017 até o último trimestre de 2019. Cada trimestre foi estimado em nove períodos, desde três meses antes da sua realização até três meses depois, em cada período a informação disponibilizada no mês anterior foi incorporada ao painel de dados e as projeções foram atualizadas. Em todos os trimestres projetados diversas variáveis foram importantes para a atualização das projeções, porém as

categorias Financeiras, Pesquisas, Indústria, Estabilidade Financeira, Vendas e Trabalho se mostram significativas em diversos períodos de estimação. O fato das variáveis de Estabilidade Financeira estarem entre as mais impactantes, também corrobora com a literatura sobre a estabilidade.

Mesmo trabalhando com séries temporais relativamente pequenas e com dados bem comportados, os modelos com estimação não paramétrica obtiveram resultados superiores a abordagem paramétrica, tanto dentro quanto fora da amostra. O modelo com estimador local constante ( $Now_{lc}$ ) se mostrou similar ou superior a média da pesquisa FOCUS em todos os períodos de estimação fora da amostra. Tal resultado demonstra o potencial da utilização de abordagem não paramétrica para previsões de variáveis macroeconômicas brasileiras, mesmo quando se dispõem de séries temporais pequenas. A abordagem não paramétrica não só se mostra como uma boa alternativa para metodologia de parâmetros variantes no tempo, mas também é capaz de encontrar distribuições mais adequadas para os parâmetros estimados.

Similar aos resultados relatados na literatura, a acurácia das previsões dos Nowcastings melhora conforme novas informações são disponibilizadas, seu melhor desempenho é nos meses seguintes à realização do trimestre de referência, sendo que os bons resultados obtidos nas projeções do Nowcasting demonstram que é possível utilizar a “bênção da dimensionalidade” dos modelos DFM, para trabalhar com um leque maior de indicadores, mesmo que ao custo de uma série temporal menor.

A alta variância dos modelos Nowcastings nos períodos anteriores à realização do trimestre de referência, sugerem que esses modelos gerariam melhores resultados sendo utilizados na combinação das suas previsões com modelos de diversas especificações, ou outros tipos de modelos que tenham melhores performances na previsão de horizontes mais longos.

Com esses resultados, esta dissertação visou realizar duas contribuições importantes para a literatura: em primeiro lugar, realizar a análise de variáveis ainda pouco exploradas em modelos Nowcasting, sobretudo no Brasil; em segundo lugar, discutir a possibilidade de utilizar abordagem não paramétrica em um modelo Nowcasting.

Devido a utilização do Nowcasting ser recente na economia, há diversas oportunidades para novas pesquisas e diversos tipos de metodologias podem ser incorporadas ao Nowcasting. Como exemplo tem-se a oportunidade de testa-lós na combinação com outros tipos de modelagem, a utilização e teste de modelagens autoregressivas na equação *bridge* e teste de coeficientes variantes no tempo na equação de dimensionamento. Tratando-se da abordagem não paramétrica pode-se testar os impactos dos diferentes tipos de *Kernel*, além de vários outros tópicos. Também, sempre há a oportunidade de explorar outros indicadores mais recentes, ou até mesmo a utilização de variáveis primárias construídas a partir de *Big Data*, como dimensionamento por imagem, e análise textual de documentos oficiais, revistas, jornais ou redes sociais.

## REFERÊNCIAS

AASTVEI, Knut Are; TROVIK, Tørres. Nowcasting norwegian GDP: the role of asset prices in a small open economy. **Empir Econ**, v. 42, p. 95–119, 2010.

ADRIAN, Tobias; SHIN, Hyun Song. Financial Intermediaries, Financial Stability, and Monetary Policy. **Federal Reserve Bank of New York Staff Reports**, n. 346, 2008.

ALLEN, Franklin; GALE, Douglas. Competition and Financial Stability. **Journal of Money, Credit, and Banking**, v. 36, n. 3, 2004.

BACEN. Relatório de Estabilidade Financeira. **Banco Central do Brasil**, v. 9/2002, 2002.

BACEN. Relatório de Estabilidade Financeira. **Banco Central do Brasil**, v. 4/2009, 2009.

BACEN. Relatório de Estabilidade Financeira. **Banco Central do Brasil**, v. 10/2019, 2019.

BAI, Jushan; NG, Serena. Determining the Number of Factors in Approximate Factor Models. **Econometrica**, v. 70, n. 1, 2002.

BAI, Jushan; NG, Serena. Determining the Number of Primitive Shocks in Factor Models. **Journal of Business Economic Statistics**, v. 25, n. 1, 2007.

BAÑBURA, Marta; GIANNONE, Domenico; MODUGNO, Michele; REICHLIN, Lucrezia. Now-casting And The Real-Time Data Flow. **European Central Bank: Working Paper Series**, n. 1564, 2013.

BAÑBURA, Marta; RÜNSTLER, Gerhard. A Look Into The Factor Model Black Box: Publication Lags And The Role Of Hard And Soft Data In Forecasting GDP. **European Central Bank: Working Paper Series**, n. 751, 2007.

BARON, Matthew; XIONG, Wei. Credit Expansion and Neglected Crash Risk. **NBER Working Papers**, v. 22695, 2016.

BISCHOF, Jannis; LAUX, Christian; LEUZ, Christian. Accounting for Financial Stability: Lessons from the Financial Crisis and Future Challenges. **CFS Working Paper Series**, n. 622, 2018.

BORIO, Claudio; FURFINE, Craig; LOWE, Philip. Procyclicality of the financial system and financial stability: issues and policy options. *In: MARRYING the macro and microprudential dimensions of financial stability.* [S.l.]: Bank for International Settlements, 2001. P. 1–57.

BORIO, Claudio; WHITE, William. Whither monetary and financial stability? the implications of evolving policy regimes. **BIS Working Papers**, n. 147, 2004.

BRAGOLI, Daniela; METELLI, Luca; MODUGNO, Michele. The Importance of Updating: Evidence from a Brazilian Nowcasting Model. **Finance and Economics Discussion Series**, n. 94, 2014.

BRUNNERMEIER, Markus K.; SANNIKOV, Yuliy. Macro, Money and Finance: A Continuous-Time Approach. **Princeton University Working Papers**, 2016a.

BRUNNERMEIER, Markus K.; SANNIKOV, Yuliy. The I Theory of Money. **Princeton University Working Papers**, 2016b.

BUNDESBANK, Deutsche. **Report on the Stability of the German Financial System.** Monthly Report. [S.l.], 2003.

CASTLE, Jennifer; HENDRY, David; KITOV, Oleg. Forecasting and Nowcasting macroeconomic variables: a methodological overview. **University of Oxford - Department Of Economics - Discussion Paper Series**, n. 674, 2013.

CHANT, John. Financial Stability As a Policy Goal. *In: ESSAYS on Financial Stability.* [S.l.]: Bank of Canada Technical Report, 2003. P. 3–4.

CROCKETT, Andrew. The Theory and Practice of Financial Stability. **GEI Newsletter Issue**, n. 6, 1997.

D'AGOSTINO, Antonello; GIANNONE, Domenico; LENZA, Michele; MODUGNO, Michele. Nowcasting Business Cycles: a Bayesian Approach to Dynamic Heterogeneous Factor Models. **Finance and Economics Discussion Series**, v. 66, 2015.

DAHLHAUS, Tatjana; GUÉNETTE, Justin-Damien; VASISHTHA, Garima. Nowcasting BRIC+M in Real Time. **Bank of Canada Working Paper**, n. 38, 2015.

DOZ, Catherine; GIANNONE, Domenico; REICHLIN, Lucrezia. A Quasi Maximum Likelihood Approach For Large Approximate Dynamic Factor Models. **European Central Bank: Working Paper Series**, n. 674, 2006.

DUISENBERG, Wim F. The Contribution of the Euro to Financial Stability. *In*: GLOBALIZATION of Financial Markets and Financial Stability—Challenges for Europe. [S.l.]: Nomos Verlagsgesellschaft, 2001. P. 37–51.

FAHLENBRACH, Rudiger; PRILMEIER, Robert; STULZ, René. Why Does Fast Loan Growth Predict Poor Performance for Banks? **NBER Working Papers**, v. 22089, 2016.

FERRARA, Laurent; MARSILLI, Clément. Nowcasting global economic growth: A factor-augmented mixed-frequency approach. **Banque de France Document de Travail**, n. 515, 2014.

FERREIRA, Pedro Costa; SPERANZA, Talitha; COSTA, Jonatha. **BETS: Brazilian Economic Time Series**. [S.l.], 2018. R package version 0.4.9. Disponível em: <https://CRAN.R-project.org/package=BETS>.

GIANNONE, Domenico; BOK, Brandyn; CARATELLI, Daniele; SBORDONE, Argia; TAMBALOTTI, Andrea. Macroeconomic Nowcasting and Forecasting with Big Data. **Federal Reserve Bank of New York Staff Reports**, n. 830, 2017.

GIANNONE, Domenico; REICHLIN, Lucrezia; SMALL, David. Nowcasting: The real-time informational content of macroeconomic data. **Journal of Monetary Economics**, v. 55, n. 4, p. 665–676, 2008.

GIANNONE, Domenico; REICHLIN, Lucrezia; SMALL, David H. Nowcasting GDP and inflation. the real-time informational content of macroeconomic data releases. **European Central Bank Working Paper Series**, n. 633, 2006.

GILCHRIST, Simon; ZAKRAJŠEK, Egon. Credit Spreads and Business Cycle Fluctuations. **American Economic Review**, v. 102, n. 4, p. 1692–1720, 2012.

GILCHRIST, Simon; ZAKRAJŠEK, Egon. Credit Spreads and Business Cycle Fluctuations. **Riksbank Macro-Prudential Conference - Stanford University**, 2015.

GREENWOOD, Robin; HANSON, Samuel. Issuer Quality and Corporate Bond Returns. **Review of Financial Studies**, v. 26, n. 6, p. 1483–1525, 2013.

HÄRDLE, Wolfgang; SIMAR, Léopold. **Applied Multivariate Statistical Analysis**. [S.l.]: Tech: Method Data Technologies, 2003. P. 488.

HAYFIELD, Tristen; RACINE, Jeffrey S. Nonparametric Econometrics: The np Package. **Journal of Statistical Software**, v. 27, n. 5, 2008. Disponível em: <http://www.jstatsoft.org/v27/i05/>.

HENDERSON, Daniel J.; PARMETER, Christopher F. **Applied Nonparametric Econometrics**. United States of America: Cambridge University Press, 2015. P. 520.

IBGE. **API SIDRA**. [S.l.], 2020. Disponível em: <http://api.sidra.ibge.gov.br/>.

JORDA, Oscar; SCHULARICK, Moritz; TAYLOR, Alan. When Credit Bites Back: Leverage, Business Cycles, and Crises. **Journal of Money, Credit and Banking**, v. 45, p. 3–28, 2013.

KALMAN, Rudolf. A new approach to linear filtering and prediction problems. **Journal of basics engineering**, v. 82, p. 35–45, 1960.

LARGE, Sir Andrew. Financial Stability: Maintaining Confidence in a Complex World. *In*: FINANCIAL Stability Review. [S.l.]: Bank of England, 2003. P. 70–74.

LIU, Philip; MATHESON, Troy; ROMEU, Rafael. Real-time Forecasts of Economic Activity for Latin American Economies: a methodological overview. **IMF Working Paper**, n. 11/98, 2011.

LÓPEZ-SALIDO, David; STEIN, Jeremy C.; ZAKRAJŠEK, Egon. Credit-Market Sentiment and the Business Cycle. **The Quarterly Journal of Economics**, v. 132, n. 3, p. 1373–1426, 2017.

MATTOS, Daiane Marcolino de; FERREIRA, Pedro Costa; VALK, Serge de; GOMES, Guilherme Branco. **nowcasting: Predicting Economic Variables using Dynamic Factor Models**. [S.l.], 2019. R package version 1.1.4. Disponível em: <https://CRAN.R-project.org/package=nowcasting>.

MIAN, Atif; SUFI, Amir; VERNER, Emil. Household Debt and Business Cycle Worldwide. **NBER Working Papers**, v. 21581, 2015.

MINSKY, Hyman. The Financial Instability Hypothesis: An interpretation of Keynes and an Alternative to 'Standard' Theory. **Nebraska Journal of Economics and Business**, v. 16, n. 1, p. 5–16, 1977.

MINSKY, Hyman P. **Estabilizando Uma Economia Instável**. São Paulo: Novo Século, 2014. P. 448.

MODUGNO, Michele; SOYBILGEN, Bari,s; YAZGAN, Ege. Nowcasting Turkish GDP and News Decomposition. **Finance and Economics Discussion Series**, v. 44, 2016.

KAGOHARA, Douglas Minoru. **Avaliando Técnicas de Nowcasting: Uma aplicação do PIB Brasileiro**. 2015. F. 48. Mestrado em Economia – Macroeconomia aplicada – Fundação Getúlio Vargas, São Paulo, Agosto 2015.

MATTOS, Pedro Montero. **Nowcasting Brazilian GDP**. 2017. F. 36. Mestrado em Economia – Economia, Econometria – Fundação Getúlio Vargas, São Paulo, Agosto 2017.

PERLIN, Marcelo. **BatchGetSymbols: Downloads and Organizes Financial Data for Multiple Tickers**. [S./], 2020. R package version 2.5.7. Disponível em: <https://CRAN.R-project.org/package=BatchGetSymbols>.

GOMES, Guilherme Branco. **Nowcasting Brazilian GDP A Performance Assessment of Dynamic Factor Models**. 2018. F. 42. Mestrado em Economia – Fundação Getúlio Vargas, Rio de Janeiro, Março 2017.

SCHINASI, Garry J. Defining Financial Stability. **IMF Working Paper**, WP/04/187, 2004.

SIDNEY, Isaac. A regulação bancária e a inclusão financeira no Brasil. **Banco Central do Brasil**, 2017.

STEIN, Jeremy. Incorporating Financial Stability Considerations into a Monetary Policy Framework. **Speech at the International Research Forum on Monetary Policy**, v. 21, 2014.

STOCK, James H.; WATSON, Mark W. Dynamic Factor Models. **Oxford Handbook on Economic Forecasting**, 2011.

THORSRUD, Leif Anders. Nowcasting using news topics: Big Data versus big bank. **Norges Bank Working Paper**, n. 20, 2016.

WELLINK, Nout. Current Issues in Central Banking. **Central Bank of Aruba**, n. 14, 2002.

YIU, Matthew S.; CHOW, Kenneth K. Nowcasting Chinese GDP: Information Content of Economic and Financial Data. **HKIMR Working Paper**, n. 04/2011, 2011.

## APÊNDICE A – VARIÁVEIS UTILIZADAS

A [Tabela 8](#) apresenta a lista das variáveis explicativas utilizadas nessa dissertação, em ordem alfabética pelas categorias. Além do nome de cada indicador, também são descritos quais os tipos (unidade de medida), fonte de dados, início da série histórica, defasagem (*Delay*) de publicação em dias, necessidade de tratamento para deflacionamento (Deflac.), onde “S” significa declacionamento pelo IPCA, “S\*” deflacionamento pelo índice de inflação EUA e “N” não, e necessidade de diferenciação (Dif.), onde “diff12” trata-se da diferenciação anual e “diff” de diferenciação mensal.

Tabela 8 – Lista das variáveis explicativas

n	Categoria	Indicador	Descrição	Tipo	Fonte	Início	Delay	Deflac	Dif
1	Agropecuária	IC-Br Agropecuária		Índice	BCB-Depec	01/1998	0	N	diff12
2	Agropecuária	Área plantada (Hectares)		Hectares	IBGE	09/2006	10	N	diff(diff12)
3	Agropecuária	Área colhida (Hectares)		Hectares	IBGE	09/2006	10	N	diff12
4	Agropecuária	Produção Cereais, leguminosas e oleaginosas		Toneladas	IBGE	09/2006	10	N	diff12
5	Energia	Consumo de energia elétrica - Brasil - Comercial		GWh	Eletrobras	01/1979	22	N	diff(diff12)
6	Energia	Consumo de energia elétrica - Brasil - Residencial		GWh	Eletrobras	01/1979	22	N	diff(diff12)
7	Energia	Consumo de energia elétrica - Brasil - Industrial		GWh	Eletrobras	01/1979	22	N	diff12
8	Energia	Consumo de energia elétrica - Brasil - Outros		GWh	Eletrobras	01/1979	22	N	diff(diff12)
9	Estabilidade	Saldo carteira de crédito		R\$ (milhões)	BCB-DSTAT	06/1988	28	S	diff(diff12)
10	Estabilidade	Inadimp. da carteira de crédito das instit. financeiras - controle público		%	BCB-DSTAT	03/2000	28	N	diff(diff12)
11	Estabilidade	Inadimp. da carteira de crédito das instit. financeiras - controle privado nacional		%	BCB-DSTAT	03/2000	28	N	diff12
12	Estabilidade	Inadimp. da carteira de crédito das instit. financeiras - controle estrangeiro		%	BCB-DSTAT	03/2000	28	N	diff(diff12)
13	Estabilidade	Índice de Basileia		%	BCB	12/2000	90	N	diff12
14	Estabilidade	Capital sobre ativos (PLA / ATA) dos bancos		%	BCB	12/2000	90	N	diff(diff12)
15	Estabilidade	PR Nível I		R\$ (milhões)	BCB	12/2000	90	S	diff(diff12)
16	Estabilidade	PR Nível II		R\$ (milhões)	BCB	12/2000	90	S	diff(diff12)
17	Estabilidade	Patrimônio de Referência (B1B2)		R\$ (milhões)	BCB	12/2000	90	S	diff(diff12)
18	Estabilidade	Patrimônio Líquido Ajustado		R\$ (milhões)	BCB	12/2000	90	S	diff(diff12)
19	Estabilidade	Ativo Total Ajustado		R\$ (milhões)	BCB	12/2000	90	S	diff(diff12)
20	Estabilidade	I007 - Retorno sobre o patrimônio líquido		%	BCB	01/2001	90	N	diff(diff12)
21	Estabilidade	I006 - Retorno sobre ativos		%	BCB	01/2001	90	N	diff(diff12)
22	Estabilidade	Índice de Liquidez (IL) - Inst. de Controle Público		Índice	BCB-Desig	01/2006	10	N	diff(diff12)
23	Estabilidade	Índice de Liquidez (IL) - Inst. de Controle Privado Nacional		Índice	BCB-Desig	01/2006	10	N	diff12
24	Estabilidade	Índice de Liquidez (IL) - Inst. Privadas de Controle Estrangeiro		Índice	BCB-Desig	01/2006	10	N	Não
25	Estabilidade	Comprometimento de renda das famílias - Amortização - Com ajuste sazonal		%	BCB-DSTAT	03/2005	56	N	diff(diff12)
26	Estabilidade	Comprometimento de renda das famílias - Juros - Com ajuste sazonal		%	BCB-DSTAT	03/2005	56	N	diff(diff12)
27	Estabilidade	Comprometimento de renda das famílias - Serviço da dívida - Com ajuste sazonal		%	BCB-DSTAT	03/2005	56	N	diff(diff12)
28	Estabilidade	Endividamento das famílias		%	BCB-DSTAT	01/2005	56	N	diff(diff12)
29	Financeiros	Ibovespa - Variação percentual mensal		%	BM&FBOVESPA	01/1987	0	N	Não
30	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 30 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
31	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 60 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
32	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 90 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
33	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 120 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
34	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 180 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
35	Financeiros	Taxa ref. de swaps DI pré-fixada (BM&F) - 360 dias (fim de período)		% a.a.	BM&FBOVESPA	09/1999	0	N	diff12
36	Financeiros	Taxa de juros - CDI acumulada no mês anualizada base 252		% a.a.	BCB-Demab	07/1986	0	N	diff12
37	Indústria	Indicadores da produção (2012=100) - Extrativa mineral		Índice	IBGE	01/2002	30	N	diff12
38	Indústria	Indicadores da produção (2012=100) - Indústria de transformação		Índice	IBGE	01/2002	30	N	diff12
39	Indústria	Produção de automóveis e comerciais leves		Unidades	Antavea	01/1993	6	N	diff12
40	Indústria	Produção de caminhões		Unidades	Antavea	01/1993	6	N	diff12
41	Indústria	Produção de ônibus		Unidades	Antavea	01/1993	6	N	diff12

continua

n	Categoria	Indicador	Fonte	Início	Delay	Deflac	Dif
42	Indústria	Produção de motocicletas	Abraçólio	01/1993	6	N	diff12
43	Indústria	UCI - indústria de transformação (FGV)	FGV	01/2001	-3	N	diff12
44	Indústria	Expedição de Caixas, Acessórios e Chapas de Papelão Ondulado	ABPO	01/2005	5	N	diff12
45	Indústria	Metais Fundidos - Ferro	ABF	11/2005	45	N	Não
46	Indústria	Metais Fundidos - Aço Ligado	ABF	11/2005	45	N	Não
47	Internacional	Exportações (Fob) - Total	MDIC/Secex	01/1954	8	S*	diff(diff12)
48	Internacional	Importações (Fob) - Total	MDIC/Secex	01/1959	8	S*	diff(diff12)
49	Internacional	Importações (Fob) - Bens de Capital	MDIC/Secex	01/1997	8	S*	diff(diff12)
50	Internacional	Importações (Fob) - Bens de Consumo	MDIC/Secex	01/1997	8	S*	diff(diff12)
51	Internacional	Balança comercial e Serviços - mensal - saldo	BCB-DSTAT	01/1995	50	S*	diff(diff12)
52	Internacional	Conta financeira - mensal - líquido	BCB-DSTAT	01/1995	50	S*	diff(diff12)
53	Internacional	Dólar americano (venda) - média de período - 3698	BCB-DSTAT	01/1953	0	N	diff(diff12)
54	Internacional	Dow Jones	Yahoo Finanças	01/1985	0	N	diff(diff12)
55	Internacional	S&P 500	Yahoo Finanças	12/1927	0	N	diff(diff12)
56	Internacional	Nasdaq	Yahoo Finanças	02/1971	0	N	diff(diff12)
57	Internacional	FTSE 100	Yahoo Finanças	04/1884	0	N	diff12
58	Internacional	Nikkei 225	Yahoo Finanças	01/1965	0	N	diff(diff12)
59	Internacional	Preço Petróleo Bruto	FMI	01/1991	2	N	diff12
60	Internacional	Preço Milho	FMI	01/1990	2	N	diff12
61	Internacional	Preço Minério de Ferro	FMI	01/1990	2	N	diff(diff12)
62	Internacional	Preço Carne	FMI	01/1990	2	N	diff12
63	Internacional	Preço Soja	FMI	01/1990	2	N	diff(diff12)
64	Internacional	Preço Açúcar	FMI	01/1990	2	N	diff(diff12)
65	Internacional	Termos de troca Commodities	FMI	01/1980	15	N	diff(diff12)
66	Internacional	Importação CIF Economias Avançadas	FMI	01/1960	90	S*	diff12
67	Internacional	Importação CIF Economias em Desenvolvimento da Ásia	FMI	01/1960	90	S*	diff12
68	Internacional	Importação CIF Economias em Desenvolvimento	FMI	01/1960	90	S*	diff12
69	Internacional	Importação CIF Hemisfério Ocidental	FMI	01/1960	90	S*	diff12
70	Internacional	Índice de preços ao consumidor EUA	FMI	01/1955	0	N	diff12
71	Monetários	Base monetária restrita (saldo em final de período)	BCB-DSTAT	01/1946	30	S	diff(diff12)
72	Monetários	Reservas internacionais - Total - mensal	BCB-DSTAT	12/1970	30	S*	diff(diff12)
73	Monetários	M1 (saldo em final de período) - Novo	BCB-DSTAT	12/2001	30	S	diff(diff12)
74	Monetários	Taxa de juros - Selic acumulada no mês anualizada base 252	BCB-Demab	07/1986	0	N	diff12
75	Pesquisas	IBC-Br (2002=100)	BCB	01/2003	52	N	diff(diff12)
76	Pesquisas	PIB mensal - valores correntes	BCB	01/1995	43	S	diff(diff12)
77	Pesquisas	Indicador de Incerteza da Economia	FGV	01/2000	2	N	diff12
78	Pesquisas	Índice de Confiança Empresarial	FGV	01/2001	2	N	diff12
79	Pesquisas	Índice da Situação Atual Empresarial	FGV	01/2001	2	N	diff12
80	Pesquisas	Índice de Expectativas Empresarial	FGV	01/2001	2	N	diff12
81	Pesquisas	Principal indicador composto	OCDE	01/1989	5	N	diff12
82	Pesquisas	Índice de confiança de negócios	OCDE	03/1995	15	N	diff12
83	Pesquisas	Índice de confiança de consumo	OCDE	03/1994	15	N	diff12
84	Pesquisas	Média FOCUS - horizonte mais curto	BCB	07/2001	0	N	diff12
85	Preços	Índice nacional de preços ao consumidor-amplo (IPCA)	IBGE	01/1990	11	N	Não

continua

n	Categoria	Indicador	Fonte	Início	Delay	Deflac	Dif
86	Preços	Índice nacional de preços ao consumidor (INPC)	IBGE	04/1979	10	N	Não
87	Preços	Índice geral de preços do mercado (IGP-M)	FGV	06/1989	-2	N	Não
88	Preços	Índice geral de preços-disponibilidade interna (IGP-DI)	FGV	02/1944	8	N	Não
89	Preços	Índice de preços ao consumidor-Brasil (IPC-Br)	FGV	01/1990	0	N	Não
90	Preços	Índice nacional de custo da construção (INCC)	FGV	02/1944	-9	N	Não
91	Preços	Índice de preços ao produtor amplo (IPA)	FGV	02/1944	0	N	Não
92	Preços	Índice de preços ao consumidor-São Paulo (IPC-Fipe)	Fipe	02/1939	17	N	Não
93	Setor Público	Dívida líquida do governo geral	BCB-DSTAT	01/1998	30	S	diff(diff12)
94	Setor Público	Resultado Primário do Tesouro Nacional	MF-STN	01/1997	30	S	diff12
95	Setor Público	Receitas tributárias - Regime de competência - Total	BCB-DSTAT	01/1990	30	S	diff12
96	Setor Público	Dívida fiscal líquida	BCB-DSTAT	12/2001	30	S	diff(diff12)
97	Setor Público	Dívida externa	BCB-DSTAT	12/2001	30	S	diff12
98	Trabalho	Índice do Emprego Formal	MTE	01/1992	21	N	diff(diff12)
99	Trabalho	Massa Salarial Ampliada PNAD	BCB-Depec	03/2004	20	S	diff(diff12)
100	Trabalho	Saldo de movimentação - Indústria	MTE - CAGED	01/2004	90	N	diff12
101	Trabalho	Saldo de movimentação - Construção Civil	MTE - CAGED	01/2004	90	N	diff12
102	Trabalho	Saldo de movimentação - Comércio	MTE - CAGED	01/2004	90	N	diff12
103	Trabalho	Saldo de movimentação - Serviços	MTE - CAGED	01/2004	90	N	diff12
104	Trabalho	Saldo de movimentação - Agropecuária	MTE - CAGED	01/2004	90	N	diff12
105	Vendas	Material de construção	IBGE	01/2003	-4	N	diff(diff12)
106	Vendas	Vendas no Varejo - Total - Brasil	IBGE	01/2000	-4	N	diff(diff12)
107	Vendas	Automóveis, motocicletas, partes e peças - Brasil	IBGE	01/2000	-4	N	diff(diff12)
108	Vendas	Comércio ampliado	IBGE	01/2003	-4	N	diff(diff12)
109	Vendas	Combustíveis e lubrificantes - Brasil	IBGE	01/2000	-4	N	diff(diff12)
110	Vendas	Vendas de veículos pelas concessionárias - Automóveis	Fenabrave	01/1990	3	N	diff(diff12)
111	Vendas	Vendas de veículos pelas concessionárias - Comerciais leves	Fenabrave	01/1990	3	N	diff(diff12)
112	Vendas	Vendas de veículos pelas concessionárias - Caminhões	Fenabrave	01/1990	3	N	diff(diff12)
113	Vendas	Vendas de veículos pelas concessionárias - Ônibus	Fenabrave	01/1990	3	N	diff12

Fonte – Elaboração própria

## APÊNDICE B – ESTATÍSTICAS DESCRITIVAS DAS VARIÁVEIS

Na [Tabela 9](#) são apresentadas algumas estatísticas descritivas das variáveis originais, antes de qualquer tratamento, seu intuito é facilitar o entendimento sobre as variáveis em que houve a necessidade da substituição de valores ausentes (Não disponíveis - ND) e *outliers* pela média móvel de dois períodos.

Tabela 9 – Estatísticas descritivas das variáveis

n	Min	1Q	Mediana	Média	3Q	Max	ND
1	4,53	4,68	4,98	4,98	5,22	5,48	0
2	4,59	4,67	4,75	4,74	4,83	4,86	1
3	4,60	4,67	4,76	4,75	4,83	4,88	1
4	4,60	4,83	5,06	5,02	5,20	5,36	1
5	4,60	4,83	5,01	4,97	5,12	5,20	0
6	4,60	4,80	4,97	4,93	5,05	5,20	0
7	4,46	4,61	4,65	4,65	4,70	4,74	0
8	4,58	4,70	4,88	4,84	4,96	5,08	0
9	4,61	5,35	5,91	5,71	6,12	6,26	0
10	4,05	4,18	4,38	4,35	4,48	4,80	0
11	4,26	4,45	4,54	4,54	4,65	4,83	0
12	4,25	4,48	4,59	4,63	4,82	5,08	0
13	4,43	4,52	4,55	4,55	4,59	4,65	1
14	4,37	4,49	4,56	4,55	4,60	4,68	1
15	4,61	5,29	5,66	5,53	5,84	6,06	1
16	4,61	5,32	5,91	5,68	5,97	6,22	1
17	4,61	5,29	5,76	5,56	5,86	6,04	1
18	4,61	5,25	5,63	5,53	5,85	6,11	1
19	4,61	5,17	5,72	5,59	5,98	6,17	1
20	3,89	4,06	4,19	4,22	4,29	4,69	3
21	3,82	4,06	4,19	4,23	4,36	4,74	3
22	3,81	4,01	4,21	4,26	4,50	4,83	0
23	3,74	4,33	4,55	4,53	4,71	4,99	0
24	3,96	4,43	4,49	4,51	4,61	4,96	0
25	4,39	4,48	4,56	4,54	4,60	4,71	1
26	4,59	4,82	4,97	4,95	5,08	5,18	1
27	4,57	4,65	4,71	4,70	4,76	4,80	1
28	4,61	4,99	5,16	5,09	5,21	5,25	1
29	-4133,33	-562,92	111,67	142,97	867,50	2828,33	7
30	3,72	4,09	4,35	4,28	4,48	4,63	7
31	3,71	4,11	4,36	4,29	4,49	4,65	7
32	3,69	4,12	4,36	4,29	4,50	4,67	7
33	3,68	4,12	4,37	4,30	4,51	4,70	7

continua

n	Min	1Q	Mediana	Media	3Q	Max	ND
34	3,67	4,12	4,38	4,31	4,52	4,72	7
35	3,68	4,15	4,39	4,33	4,52	4,76	7
36	3,33	4,04	4,34	4,24	4,47	4,61	0
37	4,41	4,65	4,72	4,71	4,76	4,88	0
38	4,37	4,53	4,61	4,60	4,70	4,80	0
39	3,86	4,74	4,92	4,87	5,01	5,23	0
40	3,37	4,43	4,76	4,73	5,04	5,54	0
41	3,32	4,58	4,91	4,84	5,17	5,47	0
42	3,29	4,26	4,64	4,57	4,85	5,23	1
43	4,47	4,51	4,58	4,56	4,60	4,65	0
44	4,46	4,69	4,77	4,75	4,82	4,95	2
45	-1721,05	-330,92	-128,95	-192,04	13,82	1263,16	1
46	-656,60	9,91	70,75	90,86	171,70	709,43	1
47	4,33	4,76	4,94	4,91	5,07	5,34	7
48	4,49	5,00	5,17	5,18	5,41	5,65	7
49	4,45	5,04	5,28	5,31	5,59	6,24	7
50	4,43	5,18	5,41	5,38	5,65	5,98	7
51	-223,46	-45,85	-3,49	-9,43	48,69	132,35	0
52	-672,48	-314,19	-193,76	-195,31	-64,98	139,30	0
53	4,28	4,43	4,64	4,73	5,02	5,42	0
54	4,08	4,66	4,86	4,89	5,08	5,53	1
55	3,98	4,61	4,80	4,86	5,11	5,52	1
56	4,10	4,73	5,03	5,13	5,47	6,05	1
57	4,11	4,58	4,67	4,65	4,76	4,86	1
58	3,81	4,14	4,58	4,49	4,78	5,01	3
59	3,94	4,53	4,74	4,75	5,05	5,27	0
60	4,61	4,90	4,96	5,07	5,27	5,62	0
61	4,61	5,20	5,47	5,51	5,94	6,33	0
62	4,52	4,69	4,81	4,79	4,88	5,15	0
63	4,61	5,13	5,22	5,28	5,48	5,74	0
64	4,30	4,62	4,81	4,85	5,06	5,49	0
65	4,61	4,61	4,62	4,62	4,62	4,63	1
66	4,43	4,74	4,84	4,81	4,91	5,00	3
67	4,44	4,85	5,08	5,02	5,17	5,40	3
68	4,42	4,88	5,01	4,97	5,12	5,26	3
69	4,38	4,82	4,94	4,90	5,04	5,13	3
70	4,60	4,68	4,74	4,73	4,78	4,85	1
71	4,60	5,05	5,36	5,29	5,52	5,76	0
72	4,61	5,79	6,20	5,99	6,24	6,27	0
73	4,61	5,08	5,36	5,25	5,43	5,73	0
74	3,33	4,04	4,34	4,24	4,47	4,61	0
75	4,58	4,72	4,77	4,76	4,81	4,87	1
76	4,61	5,03	5,39	5,30	5,57	5,76	0
77	4,48	4,60	4,68	4,69	4,76	5,16	0

continua

n	Min	1Q	Mediana	Media	3Q	Max	ND
78	4,22	4,48	4,58	4,56	4,67	4,75	0
79	4,20	4,47	4,58	4,55	4,68	4,79	0
80	4,20	4,48	4,59	4,55	4,64	4,73	0
81	4,56	4,59	4,61	4,60	4,62	4,64	0
82	4,57	4,59	4,60	4,60	4,61	4,63	1
83	4,57	4,60	4,61	4,61	4,62	4,63	1
84	-142,20	0,61	45,37	41,61	88,78	197,32	0
85	-109,52	119,05	204,76	213,58	271,43	628,57	0
86	-187,50	140,63	268,75	284,74	393,75	943,75	0
87	-379,31	44,83	165,52	173,64	300,00	720,69	0
88	-516,67	39,58	183,33	210,56	381,25	787,50	0
89	-168,42	115,79	236,84	238,97	347,37	936,84	0
90	-227,27	200,00	327,27	467,71	590,91	2672,73	0
91	-700,00	-7,14	157,14	187,27	394,64	907,14	0
92	-168,00	74,00	140,00	168,74	240,00	648,00	0
93	4,61	4,87	5,03	5,19	5,58	6,02	0
94	-716,85	10,41	72,75	72,41	143,39	582,77	7
95	4,51	4,90	5,21	5,17	5,40	5,92	7
96	4,61	4,89	5,17	5,34	5,85	6,30	0
97	4,61	8,60	9,18	9,04	9,61	10,15	0
98	4,60	4,78	4,91	4,86	4,93	4,99	3
99	4,60	4,96	5,32	5,29	5,65	5,90	0
100	-329,18	-23,96	14,15	2,22	48,27	145,29	3
101	-1050,24	-129,79	59,75	2,89	198,86	432,22	3
102	-210,86	-21,02	30,42	34,58	82,24	283,17	3
103	-364,20	5,51	80,17	53,72	125,05	285,14	3
104	-329,18	-23,96	14,15	2,22	48,27	145,29	3
105	4,39	4,77	4,90	4,87	4,98	5,13	1
106	4,53	4,91	5,05	5,01	5,10	5,43	1
107	4,52	4,90	5,04	5,03	5,19	5,48	1
108	4,52	4,93	5,04	5,01	5,12	5,38	1
109	4,56	4,72	4,79	4,80	4,88	5,03	1
110	4,47	4,84	4,99	4,99	5,16	5,53	0
111	4,41	4,86	5,11	5,17	5,50	5,88	0
112	3,68	4,55	4,91	4,85	5,22	5,58	0
113	3,74	4,64	4,91	4,85	5,13	5,45	0

Fonte – Elaboração própria

## APÊNDICE C – TESTE DE ESTACIONARIEDADE

Na [Tabela 10](#) são apresentados os valores da estatística do teste KPSS para todas as variáveis no formato original, após diferenciação anual e diferenciação mensal. O argumento "NA" é utilizado nas variáveis onde não houve o tratamento referente a coluna. Os valores críticos para a quantidade de observação são: 10% = 0,347; 5% = 0,463; 2,5% = 0,574; e 1% = 0,739.

Tabela 10 – Teste KPSS

n	original	diff12	diff(diff12)
1	3,15	0,09	NA
2	3,26	0,49	0,06
3	3,28	0,23	NA
4	3,24	0,06	NA
5	2,94	1,51	0,05
6	3,10	1,27	0,02
7	0,66	0,22	NA
8	3,18	0,51	0,03
9	3,08	2,53	0,19
10	0,96	0,39	0,05
11	0,42	0,10	NA
12	1,38	0,34	0,05
13	0,35	0,18	NA
14	1,55	0,42	0,07
15	3,06	1,97	0,05
16	2,51	1,04	0,09
17	3,01	2,01	0,05
18	3,17	1,79	0,08
19	3,18	1,82	0,07
20	1,84	0,35	0,15
21	1,93	0,39	0,14
22	0,76	0,91	0,06
23	1,18	0,17	NA
24	0,18	NA	NA
25	1,58	0,40	0,09
26	3,00	0,63	0,04
27	1,49	0,51	0,05
28	2,35	1,95	0,18
29	0,09	NA	NA
30	0,60	0,21	NA
31	0,61	0,21	NA
32	0,63	0,22	NA

continua

n	original	diff12	diff(diff12)
33	0,65	0,22	NA
34	0,69	0,22	NA
35	0,79	0,24	NA
36	0,91	0,28	NA
37	0,57	0,30	NA
38	1,39	0,24	NA
39	0,48	0,21	0,19
40	1,23	0,22	NA
41	1,11	0,20	NA
42	2,25	0,22	NA
43	2,34	0,15	NA
44	2,30	0,12	0,11
45	0,07	0,11	NA
46	0,17	0,16	NA
47	0,90	0,23	NA
48	0,65	0,46	0,04
49	0,61	0,48	0,32
50	1,03	1,00	0,04
51	0,55	0,45	0,02
52	0,52	0,34	0,03
53	2,79	0,37	0,04
54	2,87	0,34	0,04
55	2,84	0,35	0,06
56	3,12	0,34	0,04
57	1,98	0,19	NA
58	1,89	0,68	0,04
59	0,62	0,19	NA
60	0,67	0,27	NA
61	0,52	0,64	0,04
62	1,46	0,17	NA
63	0,57	0,52	0,03
64	0,54	0,45	0,03
65	0,57	0,49	0,05
66	1,21	0,09	NA
67	2,71	0,18	NA
68	1,68	0,18	NA
69	1,24	0,19	NA
70	3,24	0,17	NA
71	3,20	1,27	0,03
72	2,36	1,30	0,19
73	3,09	0,95	0,06
74	0,94	0,28	NA
75	1,31	0,74	0,03
76	3,24	1,70	0,04

continua

---

n	original	diff12	diff(diff12)
77	1,18	0,10	NA
78	1,39	0,15	NA
79	1,69	0,16	NA
80	0,97	0,14	0,16
81	0,40	0,19	NA
82	1,14	0,11	NA
83	1,35	0,21	NA
84	1,34	0,10	NA
85	0,24	NA	NA
86	0,24	NA	NA
87	0,04	NA	NA
88	0,04	NA	NA
89	0,18	NA	NA
90	0,34	0,30	0,33
91	0,04	NA	NA
92	0,17	NA	NA
93	3,17	0,93	0,06
94	0,63	0,10	0,11
95	3,01	0,21	NA
96	3,28	1,39	0,21
97	2,69	0,23	0,19
98	2,35	1,89	0,15
99	3,33	2,00	0,14
100	0,73	0,10	NA
101	1,12	0,24	NA
102	1,02	0,19	NA
103	1,29	0,21	NA
104	0,73	0,10	NA
105	1,85	0,42	0,03
106	2,32	1,58	0,07
107	0,57	0,70	0,03
108	1,71	1,11	0,05
109	0,93	1,39	0,04
110	0,64	0,48	0,04
111	1,01	0,84	0,05
112	1,22	0,35	0,05
113	0,69	0,27	NA

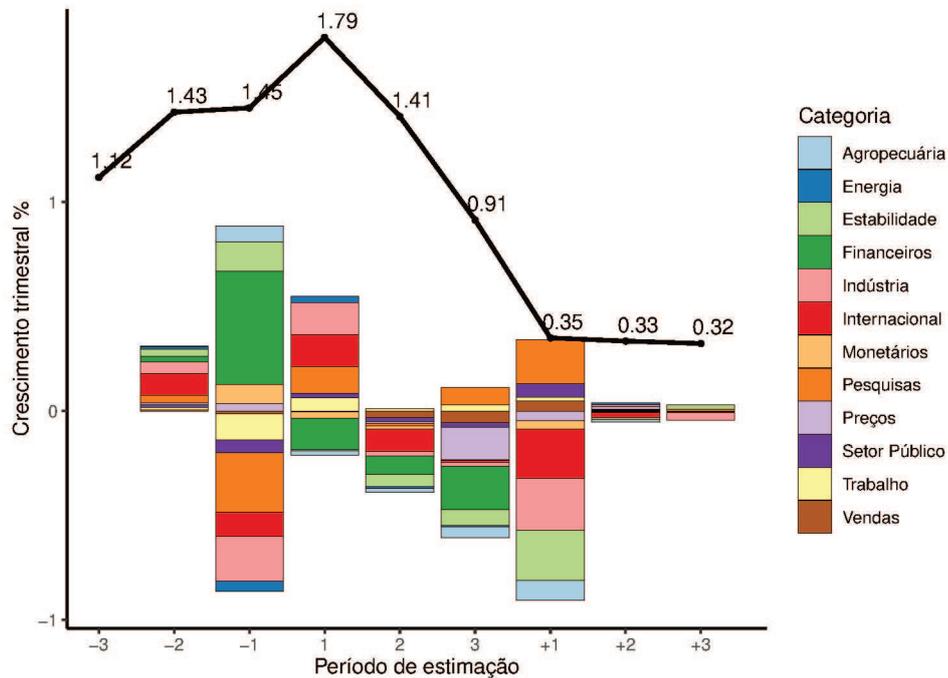
---

Fonte – Elaboração própria

## APÊNDICE D – ATUALIZAÇÃO DAS PREVISÕES

As figuras a seguir apresentam o impacto das diferentes categorias na atualização das projeções dos trimestre de 2017 até 2019 do modelo  $Now_{IC}$  (campeão de previsões), onde as linhas pretas representam os crescimentos trimestrais do PIB projetados em cada um dos períodos de estimação, enquanto os blocos são os efeitos de cada uma das categorias de variáveis (mesma unidade de mensuração do crescimento do PIB).

Figura 15 – Atualizações das previsões - 1ºT 2017



Fonte – Elaboração Própria

Figura 16 – Atualizações das previsões - 2ºT 2017

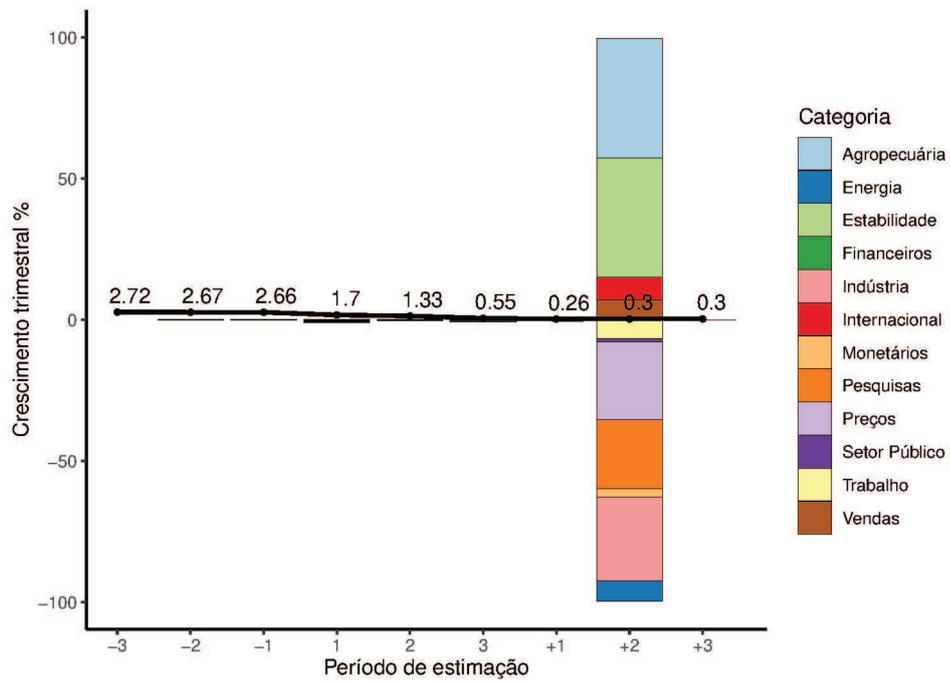


Figura 17 – Atualizações das previsões - 3ºT 2017

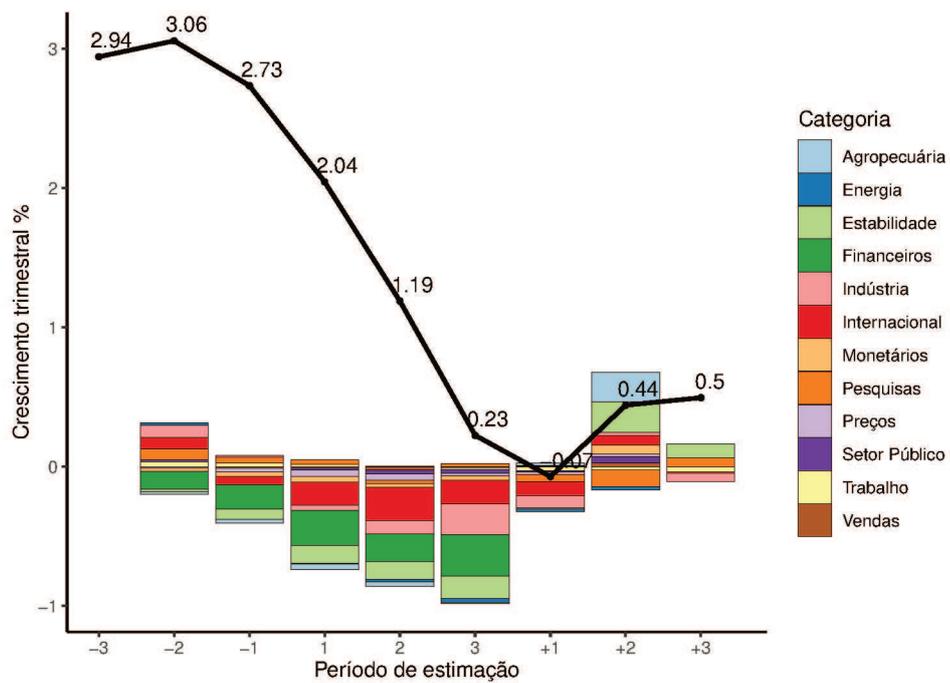
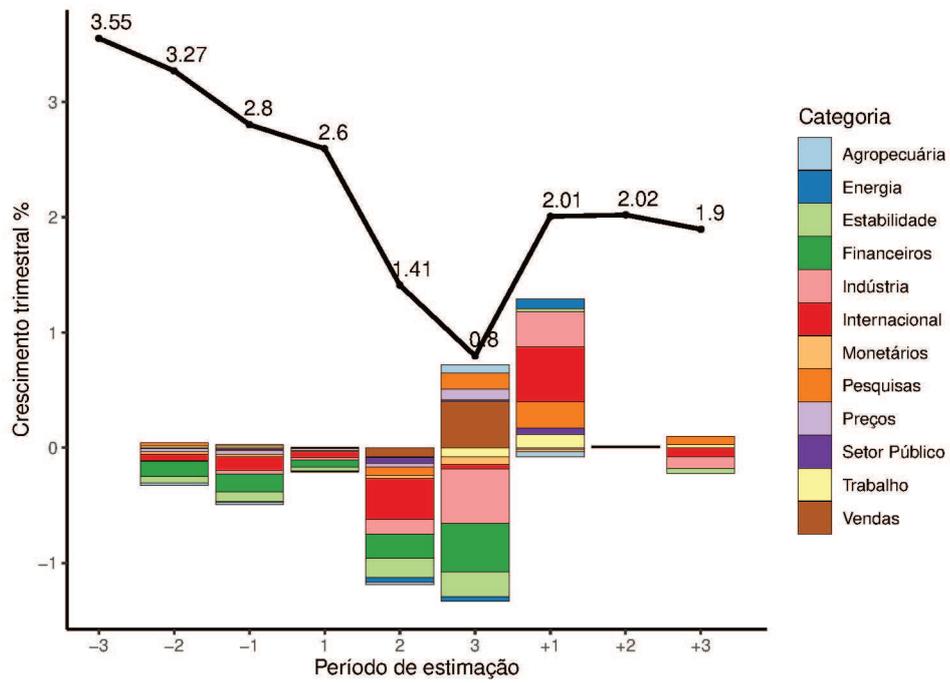
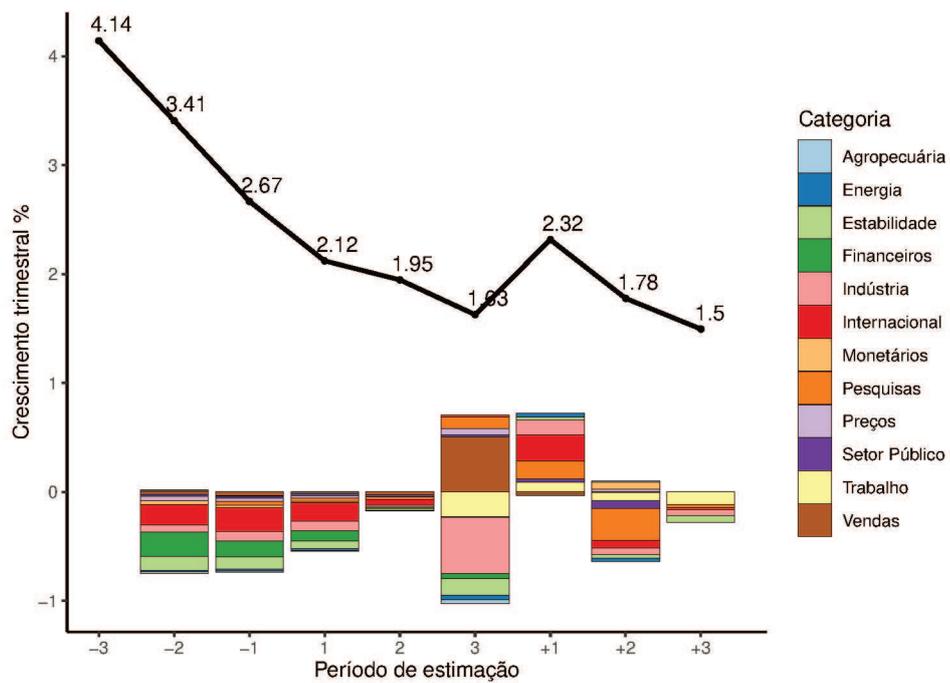


Figura 18 – Atualizações das previsões - 4ºT 2017



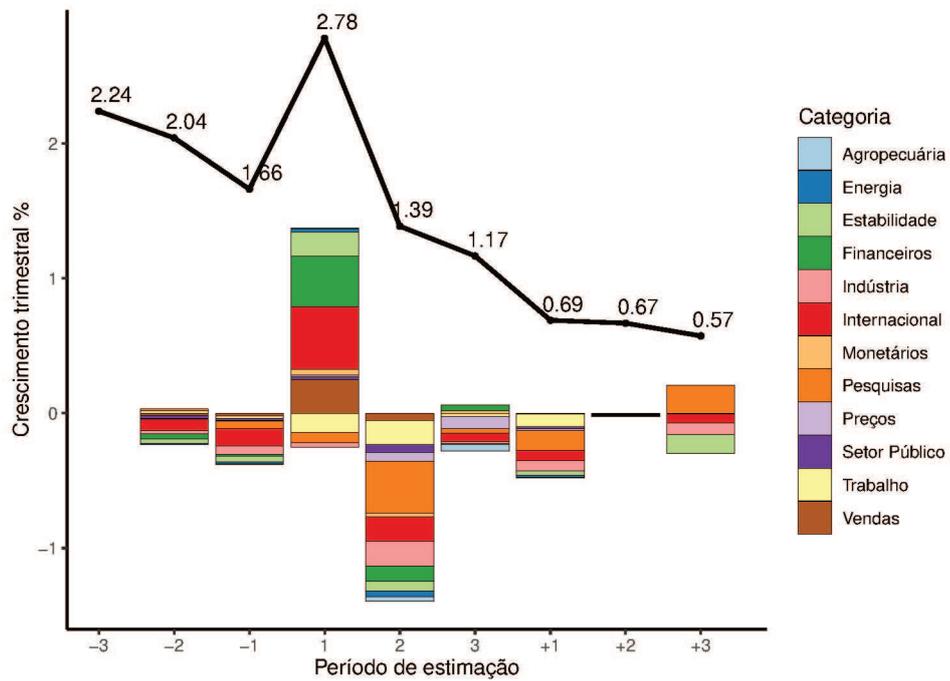
Fonte – Elaboração Própria

Figura 19 – Atualizações das previsões - 1ºT 2018



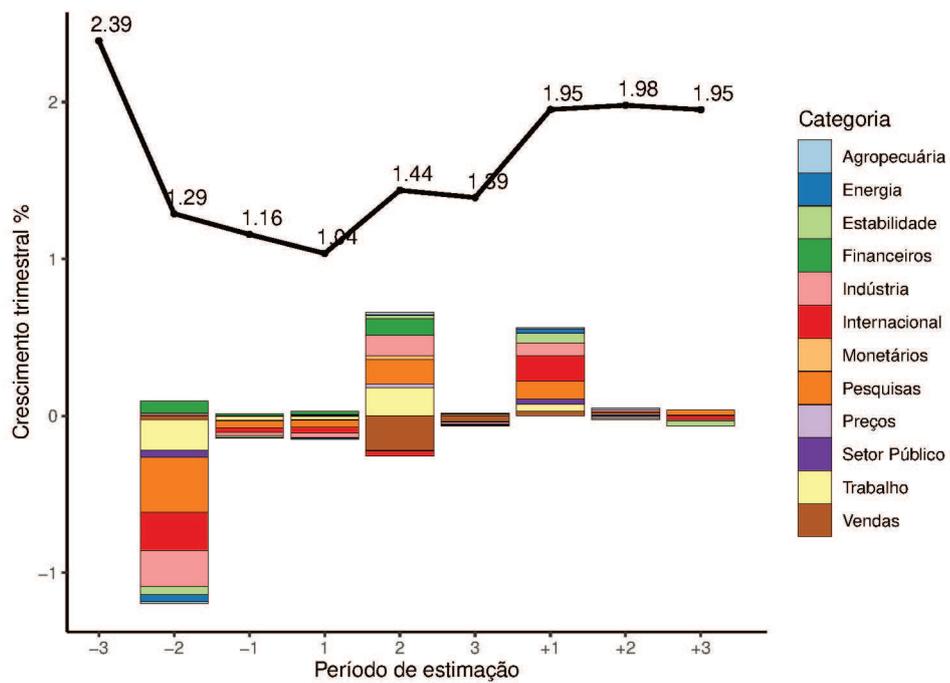
Fonte – Elaboração Própria

Figura 20 – Atualizações das previsões - 2ºT 2018



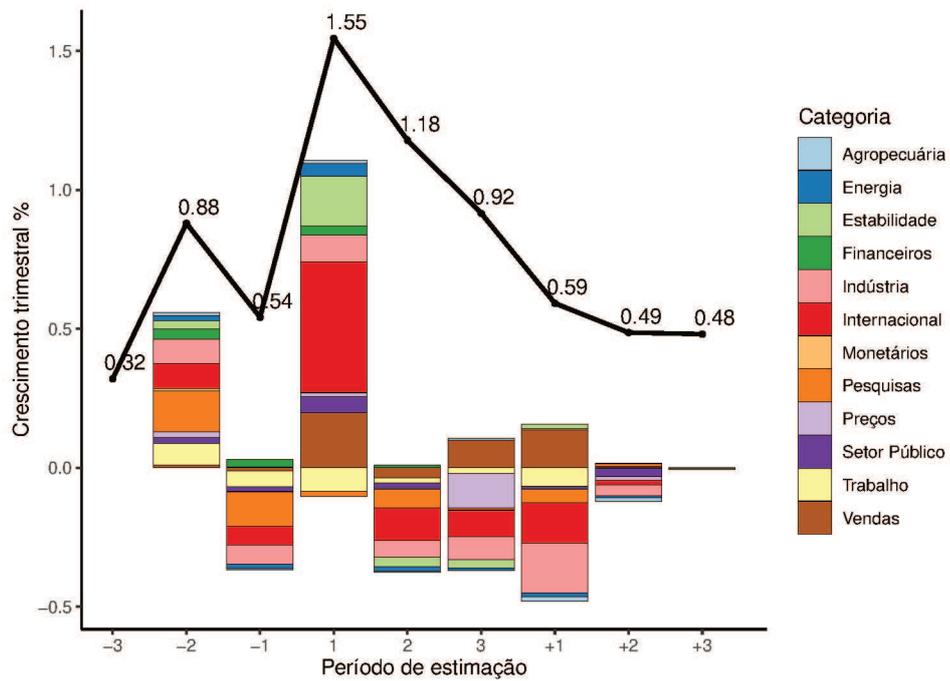
Fonte – Elaboração Própria

Figura 21 – Atualizações das previsões - 3ºT 2018



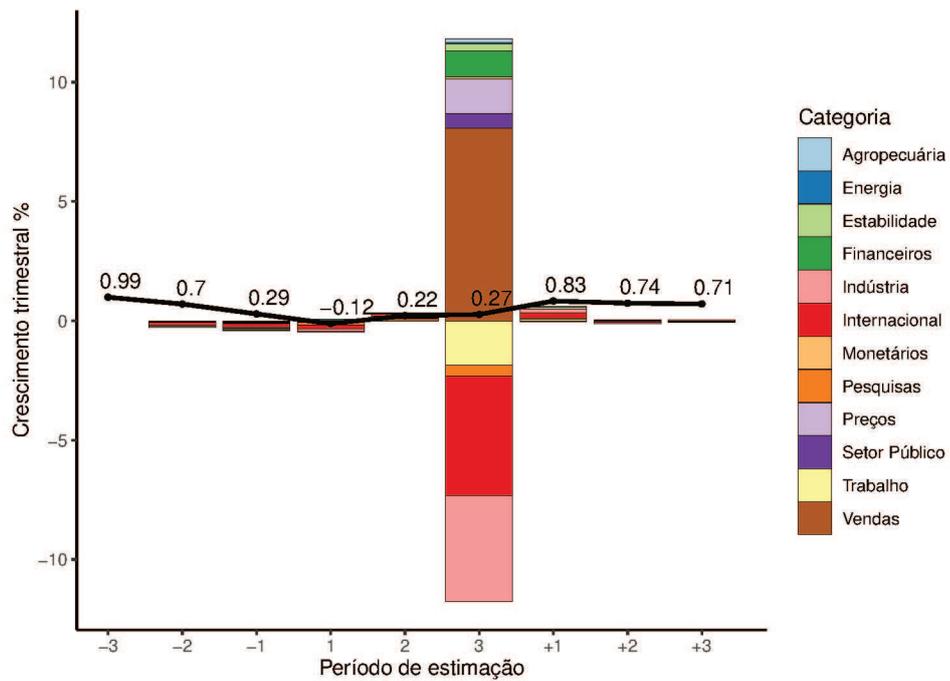
Fonte – Elaboração Própria

Figura 22 – Atualizações das previsões - 4ºT 2018



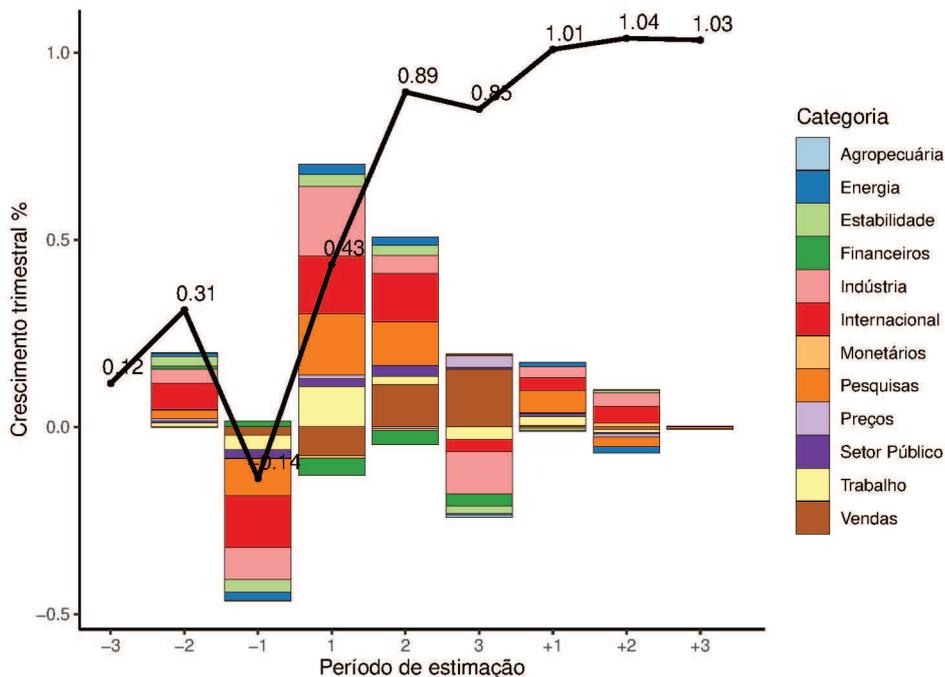
Fonte – Elaboração Própria

Figura 23 – Atualizações das previsões - 1ºT 2019



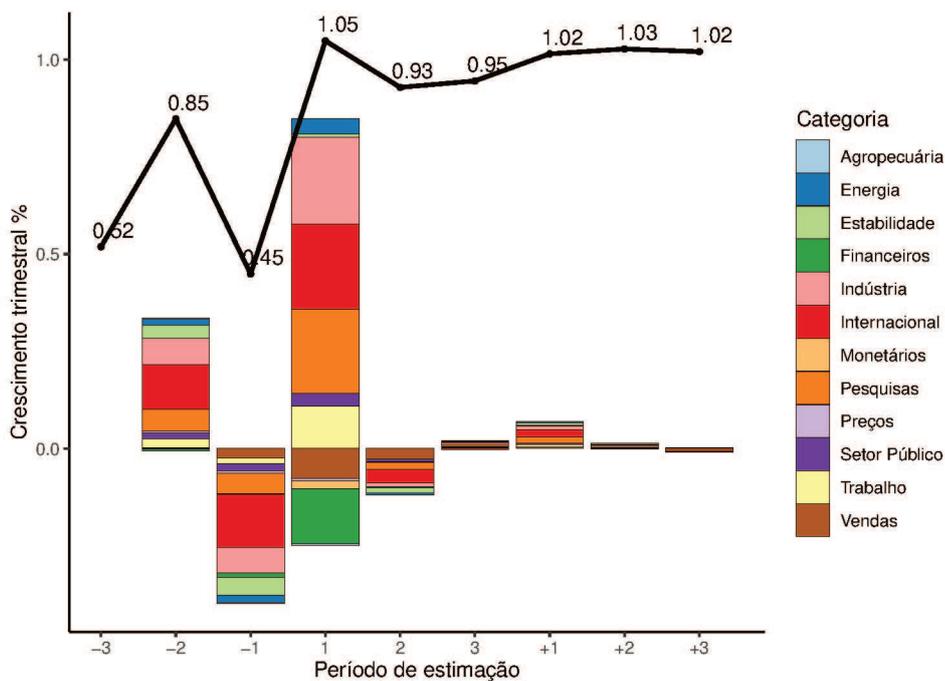
Fonte – Elaboração Própria

Figura 24 – Atualizações das previsões - 2ºT 2019



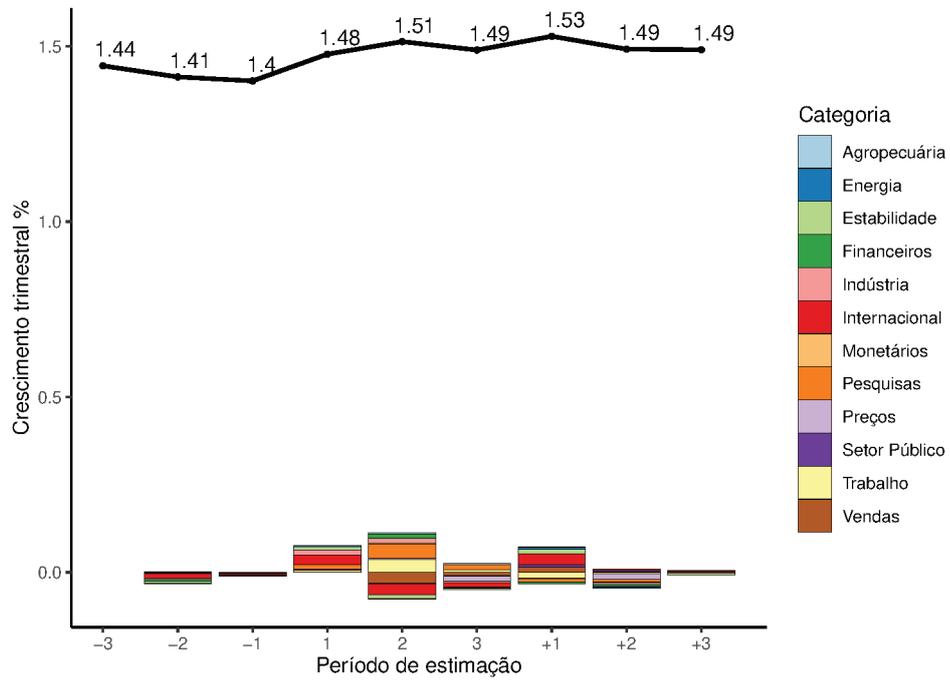
Fonte – Elaboração Própria

Figura 25 – Atualizações das previsões - 3ºT 2019



Fonte – Elaboração Própria

Figura 26 – Atualizações das previsões - 4ºT 2019



Fonte – Elaboração Própria