

idp

idn

MESTRADO PROFISSIONAL EM ECONOMIA

**CONSTRUÇÃO DE UM INDICADOR CHAVE DE RISCO PARA
A INFLAÇÃO DO BRASIL:** UMA ANÁLISE RETROSPECTIVA DAS
PREVISÕES PARA O IPCA CONTIDAS NO RELATÓRIO FOCUS
DO BANCO CENTRAL DO BRASIL

GILDO MACHADO GOMES
Brasília-DF, 2023

GILDO MACHADO GOMES

**CONSTRUÇÃO DE UM INDICADOR CHAVE DE RISCO
PARA A INFLAÇÃO DO BRASIL: UMA ANÁLISE
RETROSPECTIVA DAS PREVISÕES PARA O IPCA
CONTIDAS NO RELATÓRIO FOCUS DO BANCO
CENTRAL DO BRASIL**

Dissertação apresentada ao Programa de Pós Graduação em Economia, do Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, como requisito parcial para obtenção do grau de Mestre.

Orientador

Professor Doutor Rogério Boueri Miranda

Brasília-DF 2023

GILDO MACHADO GOMES

**CONSTRUÇÃO DE UM INDICADOR CHAVE DE RISCO
PARA A INFLAÇÃO DO BRASIL: UMA ANÁLISE
RETROSPECTIVA DAS PREVISÕES PARA O IPCA
CONTIDAS NO RELATÓRIO FOCUS DO BANCO
CENTRAL DO BRASIL**

Dissertação apresentada ao Programa de Pós Graduação em Economia, do Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, como requisito parcial para obtenção do grau de Mestre.

Aprovado em 24 / 01 / 2023

Banca Examinadora

Prof. Dr. Rogério Boueri Miranda - Orientador

Prof. Dr. Sérgio Ricardo de Brito Gadelha

Prof. Dr. Carlos Enrique Carrasco Gutierrez

G633c Gomes, Gildo Machado

Construção de um indicador chave de risco para a inflação do Brasil: uma análise retrospectiva das previsões para o IPCA contidas no relatório Focus do Banco Central do Brasil / Gildo Machado Gomes. – Brasília: IDP, 2023.

78 p. il.:Color.
Inclui bibliografia.

Trabalho de Conclusão de Curso (Dissertação) – Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa – IDP, Mestrado em Economia, Brasília, 2023.
Orientador: Prof. Dr. Rogério Boueri Miranda.

1. IPCA. 2. Política monetária. 3. Riscos estratégicos. I. Título.

CDD: 330

Ficha catalográfica elaborada pela Biblioteca Ministro Moreira Alves
Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa



RESUMO

A ideia de comparar uma previsão com um número aleatório não chega a ser inovadora. Muitos outros pesquisadores já o fizeram, como, por exemplo Egorov et al (2006), ou Kilian et al (2003). Contudo não foram encontrados trabalhos desse tipo com as previsões contidas no Boletim Focus do Banco Central do Brasil para a inflação. O estudo da dinâmica da inflação traz benefícios importantes para estabilização da economia e, conseqüentemente, para distribuição justa das riquezas do país. O trabalho consiste na implementação de um teste de validação das previsões do mercado, comparando-as com números em torno das médias passadas do próprio indicador. Os resultados encontrados evidenciam que há pouca informação nas previsões, especialmente em momentos mais turbulentos e para horizontes de tempo de médio e longo prazo. Contudo, há a possibilidade de aproveitamento dos dados presentes no relatório, não como previsões, mas como um índice de ancoragem do mercado.

Palavras-chaves: IPCA, Inflação, Previsão, Focus, Política Monetária, Riscos Estratégicos

ABSTRACT

Comparing a prediction with a random number is not a novel idea. Many other researchers have already done so, such as Egorov et al (2006), or Kilian et al (2003). However, these works were not found for the forecasts contained in the Boletim Focus of the Central Bank of Brazil for inflation. Studies of the dynamics of inflation bring important benefits for the stabilization of the economy and, consequently, for the fair distribution of the country's wealth. The work consists of a validation test of market forecasts, comparing them with numbers around the past averages of the indicator itself. The results found show that there is not much information in the forecasts, especially in turbulent times and in the medium and long term. However, there is the possibility of using the data present in the report, not as forecasts, but as a market anchoring index.

Keywords: IPCA, Inflation, Forecast, Focus, Monetary Policy, Strategic Risks

LISTA DE ABREVIATURAS E SIGLAS

IDP	Instituto Brasileiro de Direito Público
SPE	Secretaria de Política Econômica do Ministério da Economia
ABNT	Associação Brasileira de Normas Técnicas
BCB	Banco Central do Brasil
CMN	Conselho Monetário Nacional
KRI	Key Risk Indicator
RIG	Relatório Integrado de Gestão do Banco Central
COSO	Committee of Sponsoring Organizations of the Treadway Commission
ISO	International Organization for Standardization
ERM	Enterprise Risk Manager
IIA	Institute of Internal Auditors
IPCA	Índice de preços ao consumidor amplo
RMI	Regime de Metas de Inflação
CORE	Curriculum Open-access Resources in Economics
IBGE	Instituto Brasileiro de Geografia e Estatística

LISTA DE ILUSTRAÇÕES

Figura 1 Gráficos da inflação	35
Figura 2 Gráficos da inflação por mês	36
Figura 3 Gráficos da média de inflação das projeções do Focus para o IPCA por mês	36
Figura 4 Comparações para o cenário de três meses	37
Figura 5 Comparações para o cenário de seis meses	50
Figura 6 Comparações para o cenário de nove meses	51
Figura 7 Comparações para o cenário de doze meses	51
Figura 8 Gráfico com os resultados para o cenário de três meses	53
Figura 9 Gráfico com os resultados para o cenário de seis meses	54
Figura 10 Gráfico com os resultados para o cenário de nove meses	55
Figura 11 Gráfico com os resultados para o cenário de doze meses	56
Figura 12 Gráfico comparativo Aleatório versus Projeções do Mercado	56
Figura 13 Gráfico com os números de dezembro e bandas CMN	59Tabela
a	

LISTA DE TABELAS



Tabela 1

Resultado dos testes de raízes unitárias (2002 a 2022)

.....40

Tabela 2

Médias mensais para cada série

.....46

Tabela 3

Resultados das simulações

.....48

Tabela 4

Resultados dos testes de hipóteses

.....57



SUMÁRIO





1

INTRODUÇÃO

1.1 Contextualização do Tema

O tema Gestão de Riscos vem ganhando cada vez mais espaço na literatura acadêmica. E como não poderia deixar de ser, uma administração pública que pretende ser cada vez mais gerente e menos burocrática deve estar atenta a essa tendência.

Desde antes da crise de confiança (WorldCom e Tyco) que assolou os mercados mobiliários americanos no início dos anos 2000, o tema governança vem ganhando importância nas principais companhias do mundo. Essa importância foi alavancada com a crise econômico-financeira internacional de 2008-2009, a qual deixou lições importantes, e inspiraram a maioria das normas de gestão de riscos que serão apresentadas neste trabalho.

Os órgãos de controle da administração pública federal, atentos a essa tendência, vêm buscando firmar entendimento da necessidade de atenção para o tema. Desde o acórdão TCU nº 2.467/2013, é possível notar que o tema vem sendo tratado com mais atenção. Em 10 de maio de 2016 a Controladoria Geral da União (CGU), conjuntamente com o Ministério do Planejamento, Orçamento e Gestão (MPOG), publicou uma instrução normativa vinculante a todo o Poder Executivo Federal que obriga órgãos e instituições a instituírem um *framework* para controle, gestão de riscos e governança.

Como lembra Cysne (1993) o imposto inflacionário é o mais nefasto dos impostos. Atinge diretamente a população mais carente, por serem justamente os que têm menos acesso ao sistema financeiro. Corroborando a afirmação, Hoffmann (1998) concluí que a inflação está associada com maior desigualdade. Por isso, criar modelos que visem a implementação de uma política monetária mais efetiva é tão importante para construção de um país mais justo. Isso possibilitaria uma distribuição mais igual e eficiente dos recursos do país, que é o principal objetivo da economia.

A criação de valor para a sociedade vem da utilização de ferramentas que sejam capazes de dirimir os impactos ou a ocorrência de eventos de risco. Nesse contexto, uma ferramenta com capacidade

preditiva pode ser utilizada como um sinal de alerta, evitando assim danos desnecessários.

1.2 Problema de Pesquisa

A identificação de *Key Risk Indicator* (KRI) para riscos é atividade complexa, uma vez que há de se provar estatisticamente a relação entre o indicador proposto e a materialização do risco. A construção puramente lógica do indicador pode ser algo perigoso no sentido de apresentar falsos positivos, ou pior, deixar de apontar a tendência de ocorrência do risco.

No caso brasileiro, existem diversos de indicadores de previsão econômica que reportam as expectativas de mercado. Entretanto, pode-se dizer que o relatório Focus é o documento mais importante. Esse relatório resume as estatísticas calculadas considerando as expectativas de mercado coletadas até a sexta-feira anterior à sua divulgação. Referido relatório é divulgado toda a segunda-feira, e traz a evolução gráfica e o comportamento semanal das projeções para índices de preços, atividade econômica, taxa de câmbio nominal, taxa de juros Selic, entre outros indicadores.

Dito isto, o problema proposto para a monografia é: Pode-se afirmar, com significância estatística, que as previsões do relatório Focus são melhores que uma série aleatória sintética (geradas por uma simulação de Monte Carlo)?

1.3 Hipóteses da Pesquisa

A hipótese norteadora dessa pesquisa reside no fato de que, em média, as instituições cadastradas no Sistema Focus do Banco Central do Brasil (BCB) têm a capacidade de prever a trajetória da taxa de inflação medida pelo IPCA no curto e médio prazo.

Supondo-se que o principal risco estratégico da instituição seria o não cumprimento da meta de inflação definida pelo Conselho Monetário Nacional (CMN), temos a hipótese a ser testada, que é, o fato de que os dados presentes no relatório Focus seriam capazes de prever ou antecipar o comportamento da execução da meta.

Caso a hipótese seja aceita, a previsão de inflação contida no Focus poderia ser utilizada como KRI; ou um sinal de alerta para a possibilidade do risco de não atingimento da meta de inflação. Então, se houver informação nas previsões, o Focus deverá bater a série sintética proposta neste estudo.

Desta forma, é crível que a melhor previsão para a economia brasileira esteja contida nesse relatório Focus. Logo, caso a hipótese se mostre factível, no sentido de que seja possível prever o comportamento futuro da economia, espera-se encontrar alguma significância estatística nos dados do relatório e essas previsões poderiam ser KRI do risco tomado pelo BCB.

1.4 Objetivos Geral e Específico

O objetivo geral desse estudo é analisar o desempenho das instituições cadastradas no Sistema Focus, no que se refere às previsões da taxa de inflação segundo o IPCA. A fim de alcançar essa finalidade, em termos de objetivos específicos neste estudo, propõe-se testar estatisticamente as previsões de inflação contidas no relatório Focus do BCB. Caso se comprove valor estatístico nessas previsões, haverá a proposição de uma aplicação prática no processo de gestão de riscos do Banco. Mas, para que isso ocorra, será preciso antes organizar uma base de dados com todas as previsões contidas no relatório Focus; propor um modelo estatístico para a inflação e; promover uma simulação de Monte Carlo para efeitos de comparação.

Segundo o BCB, as projeções apresentadas no Focus, podem ser descritas como:

“São projeções elaboradas por bancos, gestoras de recursos, empresas não-financeiras, consultorias, associações de classe, academia etc., que possuem equipes especializadas que projetam as principais variáveis macroeconômicas, com o intuito de assessorar a tomada de decisões, tanto por profissionais da própria instituição, como por seus clientes. As projeções, em muitos casos com o auxílio de modelagem econométrica, são realizadas para variáveis relacionadas à atividade econômica, às taxas de juros e de câmbio, à variação dos índices de preços, ao balanço de pagamentos e ao setor fiscal da economia brasileira.”

1.5 Delimitação do Escopo do Estudo

Embora possa ser replicada para diversos outros indicadores econômicos, o presente trabalho estará focado apenas no comportamento do Índice de Preços ao Consumidor Amplo (IPCA). Também estará restrito a comparação do erro estocástico com os resultados do Relatório Focus do BCB, não sendo escopo a procura por outros modelos que possam ser entendidos como melhores preditores que os mencionados aqui.

1.6 Justificativa do Tema

Dentre outros efeitos adversos, a inflação é descrita também como sendo um dos impostos mais cruéis da economia, ao corroer o poder de compra da moeda, afetando assim o bem-estar das famílias. Estudar seu comportamento e, principalmente, buscar uma previsibilidade para o aprimoramento da condução da política monetária, tem uma relevância real para a economia brasileira.

As previsões do Focus são apresentadas na imprensa e utilizadas pela sociedade como uma informação de previsão de índice de preços, câmbio e agregados como o Produto Interno Bruto (PIB), entre outros. Se uma previsão é robusta e válida, pode-se esperar que haja informação nela, ou seja, que acerte mais que o modelo aleatório. Por outro lado, se é meramente a expectativa dos agentes econômicos, não se pode ou deve esperar nada além da opinião deles.

Analisar o desempenho das instituições cadastradas no Sistema Focus, no que se refere às previsões da taxa de inflação segundo o IPCA, é tema relevante ao atual debate acadêmico, com importantes implicações de política econômica. As expectativas de mercado são subsídios importantes para as decisões de política monetária, com o principal objetivo de manter a taxa de inflação sob controle. Além disso, a disponibilização das estatísticas de expectativas de mercado pelo Banco Central do Brasil possibilita que empresas e cidadãos tenham conhecimento sobre o que os agentes de mercado estão projetando, constituindo-se dessa forma ferramenta importante para o planejamento das ações de política monetária de curto, médio e longo prazos. Portanto, esse sistema ajuda na tomada de decisões monetárias no Brasil, com o principal objetivo de manter a taxa de inflação sob

controle. Além disso, o Comitê de Política Monetária (COPOM) utiliza os indicadores do Sistema Focus para definir a meta da taxa de juros Selic.

Dessa forma, o estudo proposto busca lançar luz sobre as previsões de inflação, ao destacar a relevância estatística e econômica dessas previsões e, dessa forma, contribuir para um melhor entendimento dos dados apresentados no Focus.

Além disso, uma aplicação prática a essa verificação foi proposta. A utilização de um indicador chave de risco pode ser muito útil no processo de tomada de decisão da condução da política monetária para o Brasil.



?

2

REFERENCIAL TEÓRICO

Bernanke (2007) lembra que há diversas formas de medir a expectativa de inflação futura. Entre as principais ele destaca pesquisa com consumidores, extração de dados do mercado financeiro em títulos atrelados à inflação, ou mesmo previsões de economistas profissionais, que é o caso deste estudo. Alerta-se para uma possível influência da variação dos indicadores de inflação pelas expectativas do mercado, o que causaria um problema de retroalimentação no sistema, ou seja, a inflação pode aumentar ou diminuir apenas porque o mercado acredita que ela vá aumentar ou diminuir.

Além disso, Bernanke (2007) chama atenção para a necessidade de os formuladores da política monetária conseguirem manter as expectativas dos agentes financeiros ancoradas. Isso seria, segundo ele, primordial para que bancos centrais atingissem seus objetivos. E essa afirmação nos traz uma reflexão: por mais que se conclua não haver significância estatística nas previsões, elas são primordiais para que o BCB conheça e analise quão ancoradas estão as expectativas do mercado.

Bauer *et al.* (2015) chegaram à conclusão que as expectativas de inflação baseadas na opinião de analistas e economistas seriam mais assertivas do que as expectativas obtidas de instrumentos financeiros indexados à inflação para o mercado estadunidense. Ora, essa conclusão é importante, mas um tanto previsível; pois haveria, nesses casos, além da inflação esperada em si, a cobrança de um prêmio de risco. Soma-se a isso, o fato de o período selecionado para a análise incluir a grande recessão de 2008, onde houve um momento de grande aversão a incertezas e os prêmios de risco esperados dispararam. Neste momento, o leitor mais atento já entende porque os números do Focus foram escolhidos para serem testados como preditores da inflação futura no Brasil.

Contudo, há de se ter cuidado, pois a utilização desses números pode levar o tomador de decisão a equívocos e prejuízos. Justamente por isso, é tão importante estudar quão acuradas são as previsões. O que nos leva a outro ponto a ser considerado, ainda segundo Bauer (2015), é que agentes do mercado, observando a possibilidade de manipulação das taxas de juros através das suas expectativas,

poderiam tentar fazê-lo. Ora, em linha com o problema da retroalimentação discutida por Bernanke (2007), investidores institucionais, corretoras e bancos são afetados diretamente pelas decisões do formulador de política monetária. Conhecendo-se que as taxas de inflação esperadas podem influenciar a tomada de decisão daqueles, é justo suspeitar da utilização desse mecanismo no intento de procurar influenciar no sentido que mais o beneficie.

Talvez por isso, para o mercado brasileiro, Weber (2011) concluiu que as estimativas obtidas de inflações implícitas são melhores que os estimadores do Focus a partir de um horizonte de 9 meses. Ora, mesmo com os prêmios de risco implícitos às taxas de desconto dos títulos, eles parecem mais bem precificados que as expectativas informadas. Isso poderia sugerir que as melhores projeções de inflação não são, necessariamente, reportadas para o BCB.

Entender as expectativas de inflação é tão importante que elas vêm sendo estudadas há muito tempo. HAMILTON (1985), ao estudar a racionalidade dos agentes, conclui que, para o mercado americano, as expectativas implícitas nos instrumentos financeiros são racionais e imparciais (errando para mais ou para menos sem viés) para o período de 1950 a 1982, por exemplo.

Para o caso do Focus, o BCB, na tentativa de mitigar o problema, criou um segmento do Focus para as cinco instituições com taxa de acerto maior. Contudo, Murat (2015) testou as previsões de inflação das top 5 instituições *versus* as previsões gerais e não encontrou divergência estatística para médio e longo prazo. Esse achado é importante pois autoriza o estudo dos números globais do Focus, sem a preocupação se de fato esses números globais são as melhores expectativas contidas naquele documento.

Carvalho e Minella (2009), por ocasião dos dez anos de metas de inflação no Brasil, publicaram um trabalho minucioso acerca das previsões do Focus, e os resultados obtidos mostraram que, àquela época, o desempenho das previsões vinha melhorando ao longo dos anos, e que, para o caso da inflação, se comparadas a modelos autorregressivos, se mostravam equivalentes ou superiores.

Lima e Céspedes (2003) também haviam testado as previsões do Focus contra modelos autorregressivos e concluíram que estes modelos eram superiores aos números apresentados no Focus, em se tratando de previsibilidade. O resultado encontrado pelos pesquisadores não parece ir contra as conclusões de Carvalho e Minella

(2009), uma vez que, em 2009, os autores mencionam uma melhora progressiva nas previsões do Focus. Ocorre que no período de 2005 a 2009 a inflação se mostrou particularmente bem controlada. Por isso, saber como se comportaram as previsões nos últimos dez anos será uma grande contribuição deste trabalho.

Contudo, Chernavsky (2011) chega a conclusões muito duras sobre as previsões do mercado organizadas pelo BCB no Boletim Focus. O pesquisador afirma que modelos lineares univariados simples superam a acurácia das previsões do mercado.

Nota-se, portanto, que na literatura específica sobre o tema foram encontrados alguns trabalhos que se propuseram a testar a assertividade das previsões do mercado, organizadas no Relatório Focus do Banco Central do Brasil. Nenhum, no entanto, que tenha realizado os testes sugeridos no presente estudo. E mais importante, nenhum deles se propôs a quantificar de forma matemática o quanto os números do relatório eram melhores ou piores que outros. Esse estudo contribui à literatura sobre o tema por ter se proposto a quantificar a informação contida no Focus, e ter encontrado indícios de que não é indicado a sua utilização como previsão da inflação futura. Essa afirmação é válida principalmente em momentos de turbulência para o indicador que se pretende prever.



3

3

METODOLOGIA

3.1 Abordagem Estatística

Dessa forma, o modelo proposto é bem simples: gerar um número aleatório calculado em uma distribuição normal de média dada pelos termos da série IPCA para os meses do ano (ocorridos antes da data t) e variância pelo quadrado dos desvios padrões dos últimos 3 termos da série antes do *lag* temporal testado.

De fato, se propõe uma simplificação do método de Monte Carlo proposta por Von Neumann e Ulam (1946) num modelo univariado onde a variável explicativa é a própria taxa de inflação e a medida de incerteza é dado pela variância da taxa. Este método é utilizado justamente para estimação de resultados futuros incertos. Isto se aplica perfeitamente ao tema do trabalho proposto que é a variação da inflação.

O método completo prevê a definição de um modelo com uma variável dependente (que se quer prever) e diversas variáveis explicativas e como elas interagem com a variável dependente. Depois são configuradas as distribuições de probabilidades das variáveis independentes (incertezas) para se chegar ao resultado. Ocorre que, diferentemente de outros modelos de previsão, no método de Monte Carlo não há apenas um resultado para a previsão e sim um conjunto de resultados possíveis.

A simplificação proposta é justamente pelo fato de se utilizar um modelo univariado, onde a variável explicativa é dada pela média da variável que se quer prever e a incerteza é dada pelo desvio padrão recente da série. Desse modo a saída é um conjunto de “N” simulações com resultados possíveis para a inflação futura.

Dessa forma, a medida de variância, a fim de capturar as interferências das quebras estruturais, foi calculada em uma janela móvel para cada série, representadas pelas equações abaixo:

Ruído branco de três meses, tem-se:

$$\sigma_t^2 = \left(\sum_{k=t-5}^{t-3} \frac{((x_k - \mu)^2)}{3} \right) \quad (1)$$

Onde x_k é termo de “Inflação para 3 meses” e μ é a média dos últimos 3 meses da série “Inflação para 3 meses” com defasagem de 3 meses (época da previsão do Focus).

Ruído branco de seis meses, tem-se:

$$\sigma_t^2 = \left(\sum_{k=t-8}^{t-6} \frac{((x_k - \mu)^2)}{3} \right) \quad (2)$$

Onde x_k é termo de “Inflação para 6 meses” e μ é a média dos últimos 3 meses da série “Inflação para 6 meses” com defasagem de 6 meses (época da previsão do Focus).

Ruído branco de nove meses, tem-se:

$$\sigma_t^2 = \left(\sum_{k=t-11}^{t-9} \frac{((x_k - \mu)^2)}{3} \right) \quad (3)$$

Onde x_k é termo de “Inflação para 9 meses” e μ é a média dos últimos 3 meses da série “Inflação para 9 meses” com defasagem de 9 meses (época da previsão do Focus).

Ruído branco de doze meses, tem-se:

$$\sigma_t^2 = \left(\sum_{k=t-14}^{t-12} \frac{((x_k - \mu)^2)}{3} \right) \quad (4)$$

Onde x_k é termo de “Inflação para 12 meses” e μ é a média dos últimos 3 meses da série “Inflação para 12 meses” com defasagem de 12 meses (época da previsão do Focus).

De forma análoga, as médias foram calculadas para cada termo da série de inflação nos horizontes propostos desde janeiro de 1997 até o mês anterior ao *lag* proposto. Dessa forma a janela de observações dos últimos meses terá mais observações que as primeiras. Basicamente o que se propõe é utilizar a média simples para cada mês do ano com os dados da inflação acumulada para três, seis, nove e doze meses até o mês em que as projeções do Focus foram calculadas.

Essas informações de média e variância serão utilizadas para gerar um ruído que será analisado como uma possível aposta para o futuro e a distância entre o ruído gerado e a inflação realizada no mês será comparada com a distância entre o número previsto pelo Boletim Focus.

O modelo de *back-testing* dos números do Boletim Focus consiste em gerar muitas vezes esse ruído e contar quantas vezes ele fica mais próximo do realizado que o projetado pelo mercado. Para o presente trabalho foi escolhido o número de 100.000 simulações por mês.

Dessa forma, para cada mês de cada uma das séries (Inflação3m, Inflação6m, Inflação9m e Inflação12m) serão gerados 100.000 ruídos ou erros (ε_t) em uma distribuição normal de média dada pelo mês que se quer testar (\bar{x}_m) e variância (σ_t^2), dada pelas fórmulas acima. Cada um desses erros será testado contra o previsto pelo mercado e então haverá para cada mês a informação de qual foi mais eficiente, o aleatório ou o Boletim Focus.

Em uma tentativa de quantificar o quão melhor é a informação do Focus, serão realizados testes de hipóteses para cada série temporal (Inflação3m, Inflação6m, Inflação9m e Inflação12m) dos comparativos entre aleatório e Focus.

Como se sabe, o teste de hipóteses é uma técnica capaz de averiguar uma afirmação para um determinado conjunto de dados, associando a esse veredito um nível máximo de erro. Isto é, ao se fazer uma afirmação sobre parâmetros de uma determinada população, deseja-se comprovar se os resultados experimentais advindos de uma amostra contrariam ou não a afirmação realizada. Usualmente, utiliza-se 1%, 5% ou 10% de significância estatística, dependendo do grau de certeza desejado no estudo.

Então, o objetivo do teste proposto é estabelecer um método que permita certificar se os dados da amostra de 236 meses de

novembro de 2002 à junho 2022 irão corroborar as hipóteses estatísticas que serão geradas. Para o correto entendimento do método, inicia-se aqui a descrição do problema.

O resultado do método descrito até este momento são, para cada conjunto de dados (três, seis, nove e doze meses à frente), cem mil resultados simulados para cada mês da amostra. Para cada uma dessas cem mil simulações é possível medir o erro entre o resultado simulado e a inflação medida, fica-se então com cem mil erros para cada mês em cada um dos conjuntos de dados. Ocorre que também está disponível a média das previsões realizadas para cada mês e cada conjunto de dados. Dessa forma se propõe para cada mês e cada conjunto de dados analisar em cada um dos cem mil resultados simulados quem esteve mais próximo do resultado que viria a ser medido. Por fim, soma-se todos os eventos em que o Focus esteve mais próximo da inflação medida e se terá quatro tabelas (uma para cada conjunto de dados) com duas colunas: “mês” e “quantidade de vezes que o Focus esteve mais próximo do resultado medido que o resultado simulado”

Assim, tem-se uma amostra de 236 meses e um parâmetro que se quer testar, o número de vezes que a média dos respondentes do Focus foi mais assertiva que a simulação proposta. Isso, por si só, já permitiria uma afirmação do tipo: “Para a amostra colida, no conjunto de dados trimestral (ou semestral ou nonamestral ou anual) o Focus acerta “X%” ou mais que o resultado simulado”. Ocorre que essa afirmação é pobre e não dá ideia do todo, apenas da amostra em si.

Para melhorar a conclusão, faz-se necessário estudar os dois erros que se pode cometer com a afirmação descrita acima:

Erro tipo *i*: Afirmar que a previsão do Focus ficará mais próxima da inflação medida menos que X% das vezes, e o na verdade ficar comprovado que o Focus fica mais próximo da inflação medida mais ou igual a X%.

Erro tipo *ii*: Afirmar que a previsão do Focus ficará mais próxima da inflação medida pelo menos X% das vezes, e o na verdade ficar comprovado que o Focus fica mais próximo da inflação medida menos que X%.

Contudo, para facilitar o entendimento do teste proposto, pode-se definir duas hipóteses numeradas, que se complementam no universo de dados e serão testadas em cada conjunto de dados.

H_0 : A previsão do Focus será mais assertiva pelo menos “um número a ser definido” (γ) que as cem mil simulações geradas para um mês. De forma resumida: $P \leq \gamma$, onde P é a quantidade de vezes em que a previsão do Focus esteve mais próxima da inflação nos cem mil cenários propostos.

H_1 : A previsão do Focus será menos assertiva que “um número a ser definido” (γ) que as cem mil simulações geradas para um mês. De forma resumida: $P > \gamma$, onde P é a quantidade de vezes em que a previsão do Focus esteve mais próxima da inflação nos cem mil cenários propostos.

A partir daqui pode-se definir a probabilidade de incidência dos erros *i* e *ii* como:

$$\mathbf{Prob(\text{erro } i) = Prob(P > \gamma \mid H_0 \text{ é verdadeira}) = \alpha} \quad \mathbf{(5)}$$

$$\mathbf{Prob(\text{erro } ii) = Prob(P \leq \gamma \mid H_1 \text{ é verdadeira}) = \beta} \quad \mathbf{(6)}$$

Onde: “ γ ” é exatamente o número que proporciona os coeficientes “ α ” nos níveis de significância estatística de 10%, 5% e 1%. A ideia é ir variando o “ γ ” até o “ α ” chegar em níveis muito próximos aos propostos. Ou seja, há uma tabela com 236 observações com números que vão de zero a quantidade de simulações realizadas (no caso: cem mil).

Em outras palavras, α é a probabilidade de rejeitar a hipótese H_0 (ou aceitar a hipótese H_1) dado que H_0 era, na verdade, válida. Ao se rejeitar H_0 , implicitamente se aceita H_1 . No caso proposto, o H_1 é justamente o limite da capacidade de acerto do Focus em relação às simulações sintéticas propostas. Ou seja, se torna possível a afirmação de que o Focus não acertará mais que “ γ ” vezes (H_1) com um nível de significância “ α ”.

Dessa forma, para cada um dos quatro cenários (três, seis, nove e doze meses) haverá três γ : $\gamma_{1\%}$, $\gamma_{5\%}$ e $\gamma_{10\%}$, que serão números inteiros entre zero e a quantidade de simulações realizadas. Estes, representam os números exatos de cenários cujo teste indica, com o nível de certeza escolhido “ α ”, ser possível afirmar a hipótese alternativa (H_1), qual seja: A previsão do Focus será menos assertiva que “um número a ser definido” (γ) que as cem mil simulações geradas para um mês.

Ao dividir $\gamma_{1\%}$, $\gamma_{5\%}$ e $\gamma_{10\%}$ pela quantidade de simulações geradas (N), Passa-se a afirmar que:

Com 1% de nível de significância, O Focus será menos assertivo em $\gamma_{1\%}$ % de N cenários propostos pela gaussiana deste trabalho, com 5% de nível de significância, O Focus será menos assertivo em $\gamma_{5\%}$ % de N cenários propostos pela gaussiana deste trabalho, com 10% de nível de significância, O Focus será menos assertivo em $\gamma_{10\%}$ % de N cenários propostos pela gaussiana deste trabalho. Essa afirmação será repetida para os quatro cenários propostos: três meses à frente, seis meses à frente, nove meses à frente e doze meses à frente.¹

Entretanto, a fim de implementar a metodologia aqui descrita (que pressupõe as séries estacionárias em nível), é necessário analisar as propriedades de estacionaridade das séries temporais a serem utilizadas por meio de testes de raízes unitárias.

3.2 Testes de Raiz Unitária

Inicialmente, para obter adequadamente o processo de geração das séries utilizou-se um conjunto de testes de estacionariedade, tanto lineares quanto com quebras estruturais. Foram aplicados os testes de raiz unitária modificados de Dickey-Fuller (ADF^{GLS}) e de Phillips-Perron (MZ_{α}^{GLS}), propostos por Elliot, Rottemberg e Stock (1996), assim como Ng e Perron (2001), os quais superam os problemas de baixo poder estatístico e distorções de tamanho dos testes tradicionais de Dickey e Fuller (1979, 1981), Said e Dickey (1984) e de Phillips e Perron (1988).

As modificações no teste de raiz unitária de Dickey e Fuller (1979, 1981) e de Said e Dickey (1984) fundamentam-se em dois aspectos centrais: (a) a extração de tendência em séries de tempo usando mínimos quadrados ordinários (OLS) é ineficiente, e; (b) a importância de uma seleção apropriada à ordem de defasagem do termo aumentado, de modo a obter uma melhor aproximação para o verdadeiro processo gerador de dados.

Para o primeiro caso, Elliot, Rottemberg e Stock (1996) propõem usar mínimos quadrados generalizados (GLS) a fim de extrair a tendência estocástica da série. Para isso, emprega-se o procedimento padrão para estimar a estatística ADF^{GLS} como sendo a estatística t para testar a hipótese nula $H_0: \beta_0 = 0$, de presença de raiz unitária contra a

¹ Essa implementação foi realizada no *software* R e pode ser encontrada no apêndice B desta dissertação.

hipótese alternativa $H_A: \beta_0 < 0$, de que a série é estacionária. A regressão estimada por mínimos quadrados ordinários é determinada por:

$$\Delta \tilde{y}_t = \beta_0 \tilde{y}_{t-1} + \sum_{j=1}^k \beta_j \Delta \tilde{y}_{t-j} + e_{tk} \quad (7)$$

na Equação (5), \tilde{y}_t define a série com tendência removida por mínimos quadrados generalizados, Δ o operador de primeiras diferenças e e_{tk} o resíduo não autocorrelacionado e homocedástico.

Com relação ao segundo aspecto, Ng e Perron (2001) demonstram que os critérios de informação de Akaike (AIC) e de Schwarz (SIC) tendem a selecionar baixos valores à defasagem k , quando se tem uma grande raiz negativa (próximo a -1) no polinômio de médias móveis da série, conduzindo os testes de raízes unitárias a importantes distorções.

Esta situação motivou o desenvolvimento do critério modificado de informação de Akaike (MAIC) à seleção da defasagem autorregressiva, de modo a minimizar as distorções provocadas por seleção inadequada de defasagem na Equação (1). O MAIC é projetado para selecionar um comprimento de defasagem relativamente longo na presença de uma raiz média-móvel próxima da unidade, a fim de evitar distorções, e um comprimento de defasagem menor na ausência de tal raiz, de modo que o poder do teste não fica comprometido. O teste ADF^{GLS} usa a estatística t (mínimos quadrados ordinários) correspondente a β_0 na referida Equação.

Ng e Perron (2001) sugeriram que as mesmas modificações propostas também fossem aplicadas ao teste tradicional de Phillips e Perron (1988), originando o teste $\underline{MZ}_\alpha^{GLS}$. Particularmente, as versões modificadas definem os testes $\underline{MZ}_\alpha^{GLS}$, \underline{MSB} e \underline{MZ}_t^{GLS} , os quais baseiam-se em:

$$\underline{MZ}_\alpha^{GLS} = (T^{-1} \mathbf{y}_T^d - \hat{\lambda}^2) \left(2T^{-2} \sum_{t=1}^T y_{t-1}^d \right)^{-1} \quad (8)$$

$$\underline{MSB} = \left(T^{-2} \sum_{t=1}^T y_{t-1}^d / \hat{\lambda}^2 \right)^{1/2} \quad (9)$$

$$\underline{MZ}_t^{GLS} = \underline{MZ}_\alpha^{GLS} \times \underline{MSB} \quad (10)$$

Por meio de simulações, Ng e Perron (2001) mostraram que a aplicação conjunta de GLS para extrair a tendência determinista e do critério de seleção de defasagens MAIC produzem testes com maior poder, mas menores distorções de tamanho estatístico quando comparados aos testes tradicionais de *Augmented* Dickey e Fuller e Phillips-Perron. Os valores críticos das estatísticas ADF^{GLS} e $\underline{MZ}_\alpha^{GLS}$ estão reportados em Ng e Perron (2001), Tabela 1.

Contudo, mesmo os testes modificados ADF^{GLS} e $\underline{MZ}_\alpha^{GLS}, \underline{MSB}$ e \underline{MZ}_t^{GLS} possuem baixo poder na presença de quebras estruturais, tornando-se viesados no sentido da não rejeição da hipótese nula de existência de raiz unitária quando a série é estacionária. Ao lidar com dados de séries temporais, os pesquisadores devem estar atentos a possíveis quebras estruturais. Uma quebra estrutural ocorre quando o comportamento de uma série muda abruptamente em um determinado ponto no tempo. Essas quebras geralmente resultam de choques exógenos, por exemplo, choques de preços de commodities, conflitos, mudanças de política e mudanças de regime cambial e/ou monetário.

Na análise econométrica, uma das principais premissas é que estatísticas descritivas (parâmetros), como a média e o desvio padrão, são relativamente estáveis ao longo do tempo. No entanto, quebras estruturais geralmente distorcem essas estatísticas. Como resultado, os parâmetros podem não mais caracterizar com precisão as propriedades das séries e os métodos econométricos podem gerar estimativas enviesadas e inconsistentes e, como resultado, previsões e estimações ruins. Além disso, Maddala e Kim (1999) explicam que mudanças estruturais afetam os resultados dos testes de raízes unitárias, cointegração e causalidade. Em vista disso, na análise de estacionariedade serão considerados dois testes de raízes unitárias que consideram a presença de quebra estrutural.

O estudo de Perron (1989) ilustra a importância de se incluir uma quebra estrutural nos testes tradicionais de raízes unitárias ao mostrar que, um viés existe contra a rejeição da hipótese nula de uma raiz unitária quando a série temporal, sob investigação, é estacionária ao redor de uma quebra estrutural. Foram considerados inicialmente três modelos de quebra estrutural. O Modelo A, que é conhecido como modelo *crash*, permite a mudança de um período no nível. O Modelo B,

que permite a existência de uma quebra na tendência da série de tempo. E o Modelo C, que é conhecido como o modelo *changing growth path*, inclui mudança de um período em ambos nível e tendência.

Especificamente, a quebra estrutural é tratada como um evento exógeno, conhecendo-se sua data de ocorrência. Seja τ o período anterior à quebra estrutural, de modo que a hipótese nula é que a série y_t segue um processo de raiz unitária com quebra estrutural no período $t = \tau + 1$, contra a hipótese alternativa de que y_t é estacionária. Em sua forma geral, o denominado modelo (C), considera quebra de intercepto e de tendência e é expresso por:

$$y_t = a_0 + a_1 y_{t-1} + a_2 t + \mu_1 D_L + \mu_2 D_P + \mu_3 D_T + \sum_{i=1}^k \beta_i \Delta y_{t-i} + \varepsilon_t \quad (11)$$

em que a variável *dummy* de impulso $D_P = 1$ se $t = \tau + 1$ e zero, caso contrário; variável *dummy* de nível $D_L = 1$ se $t > \tau$ e zero, caso contrário; e variável *dummy* de tendência $D_T = t - \tau$ se $t > \tau$ e zero, caso contrário; a_0 é o intercepto; a_2 é o coeficiente da tendência determinística t ; o termo de resíduo é um ruído branco não autocorrelacionado e homocedástico, $\varepsilon_t \sim i.i.d. (0, \sigma^2)$; k é o número de defasagens escolhido de acordo com os critérios usuais de seleção de defasagens. μ_1, μ_2, μ_3 e β são parâmetros a serem estimados². Os resíduos obtidos na equação em (5) são usados para estimar a equação por meio mínimo quadrados ordinários:

$$e_t = a_1 e_{t-1} + u_t \quad (12)$$

Sob a hipótese nula de raiz unitária, o valor teórico de a_1 é unitário. Sendo os resíduos independentes e identicamente distribuídos, a distribuição de a_1 dependerá da razão tamanho da amostra pré-quebra/tamanho total da amostra, denotada por $\lambda = \tau/T$, em que T é o número total de observações. Assim sendo, o termo “ λ ” determina a fração de quebra no teste de Perron (1989), representando a proporção de observações que ocorreram

² A hipótese nula do Modelo C impõe as seguintes restrições nos parâmetros da equação (5): $a_1 = 1, \mu_1 \neq 0, \mu_2 \neq 0$ e $a_2 = \mu_3 = 0$, ao passo que a hipótese alternativa, tem-se: $|a_1| < 1, a_2 \neq 0, \mu_1 = 0, \mu_2 \neq 0$ e $\mu_3 \neq 0$. Perron (1989) prevê, ainda, dois casos particulares de mudanças no intercepto (Modelo A) ou na inclinação da série (Modelo B).

anteriormente à quebra estrutural, em relação ao número total de observações.

Caso os resíduos sejam correlacionados, deve-se então estimar a Equação (10) na forma do teste de Dickey-Fuller Aumentado (ADF) com seleção apropriada de defasagens para corrigir a autocorrelação. Para essa finalidade, utiliza-se a abordagem do geral para o específico, conforme sugerido por Campbell e Perron (1991), onde se escolhe *a priori* um número máximo de defasagens ($p_{máximo}$), as quais vão sendo eliminadas uma a uma, caso o coeficiente da última defasagem se apresente não significativo.

Todavia, Christiano (1992) criticou a abordagem de Perron (1989) sob o fundamento de que os pontos de quebra não devem ser tratados como exógenos uma vez que a imposição de uma data de quebra envolve uma questão de *data-mining*. Para Christiano (1992), a escolha da data da quebra estrutural está correlacionada com os dados, o que diminui a validade do procedimento proposto por Perron (1989) de seleção exógena da quebra. Pesquisas posteriores mudaram a hipótese de Perron (1989) de que o ponto de quebra é conhecido *a priori* e adotaram um procedimento endógeno para determinar o ponto de quebra a partir dos dados.

Vogelsang e Perron (1998) desenvolveram um teste de raiz unitária com estimação do ponto de quebra de forma endógena, baseando-se nos modelos A, B e C de Perron (1989) e nos métodos *Innovation Outlier* (IO) e *Additive Outlier* (AO). O modelo AO permite uma mudança súbita na média (*crash model*), enquanto o modelo IO permite mudanças mais graduais. Assim, os dois modelos são usados para verificar a hipótese de estacionariedade: quebra no intercepto, quebra no intercepto e na tendência, ambas em nível e em primeira diferença. O modelo geral é expresso na forma da seguinte equação:

$$y_t = \mu_0 + \mu_1 y_{t-1} + \mu_2 t + \beta_1 D_l + \beta_2 D_p + \beta_3 D_t + \sum_{i=1}^j \rho_i \Delta y_{t-i} + \varepsilon_t \quad (13)$$

Em que y_t é a série de dados, μ_0 o intercepto, μ_2 o coeficiente de tendência determinística; β_1 , β_2 e β_3 são parâmetros de quebra a serem estimados; D_l , D_p e D_t são variáveis *dummies* para a quebra no intercepto, quebra no nível e quebra na tendência, respectivamente; ρ_i e μ_1 são parâmetros desconhecidos, Δ é o operador de primeira diferença, j é a melhor defasagem selecionada pelo critério de informação Akaike; e ε_t são inovações independentes e identicamente distribuídas (i.i.d).

Saikkonen e Lütkepohl (2002), Lanne, Lütkepohl e Saikkonen (2002), e Lanne, Lütkepohl e Saikkonen (2003) propuseram que as quebras estruturais podem ocorrer ao longo de um número de períodos como também a uma transição suave para um novo nível. Portanto, uma função de mudança de nível, que é conhecida pela forma não linear geral $f_t(\theta)' \gamma$, é acrescentada ao termo determinístico μ_t do processo gerador de dados. Assim, o modelo é expresso pela expressão (12):

$$q_t = \mu_0 + \mu_1 t + f_t(\theta)' \gamma + v_t \quad (14)$$

em que θ e γ são parâmetros escalares desconhecidos, t é uma tendência temporal e v_t são erros residuais gerados por um processo AR(p) com possível raiz unitária.

Além da possibilidade de se modelar quebra estrutural com uma variável *dummy* de impulso, a mudança na função $f_t(\theta)' \gamma$ pode ser: (i) uma variável *dummy* de mudança simples com data de mudança T_b (*shift dummy*); (ii) baseada em uma função de distribuição exponencial que permite uma mudança gradual não linear para um novo nível começando no período T_b (*exponential shift*); (iii) uma função racional no operador de defasagem aplicado a uma *dummy* de mudança (*rational shift*).

Operacionalmente, o teste de raiz unitária proposto por Saikkonen e Lütkepohl (2002), Lanne, Lütkepohl e Saikkonen (2002), e Lanne, Lütkepohl e Saikkonen (2003) está baseado na estimação do termo determinístico por mínimos quadrados generalizados (GLS) e na subtração dessa tendência da série original, seguida de um teste ADF desenvolvido às séries ajustadas. Se a data da quebra é desconhecida, recomenda-se a escolha de uma ordem de defasagens maior no primeiro passo e, então, obter a data de quebra que minimiza a soma dos erros quadrados generalizada do modelo em primeiras diferenças. A escolha do número ótimo de defasagens se baseia nos resultados apresentados pelo critério de informação de Akaike (AIC).



4

4

DESCRIÇÃO DOS DADOS E TRATAMENTO DAS VARIÁVEIS

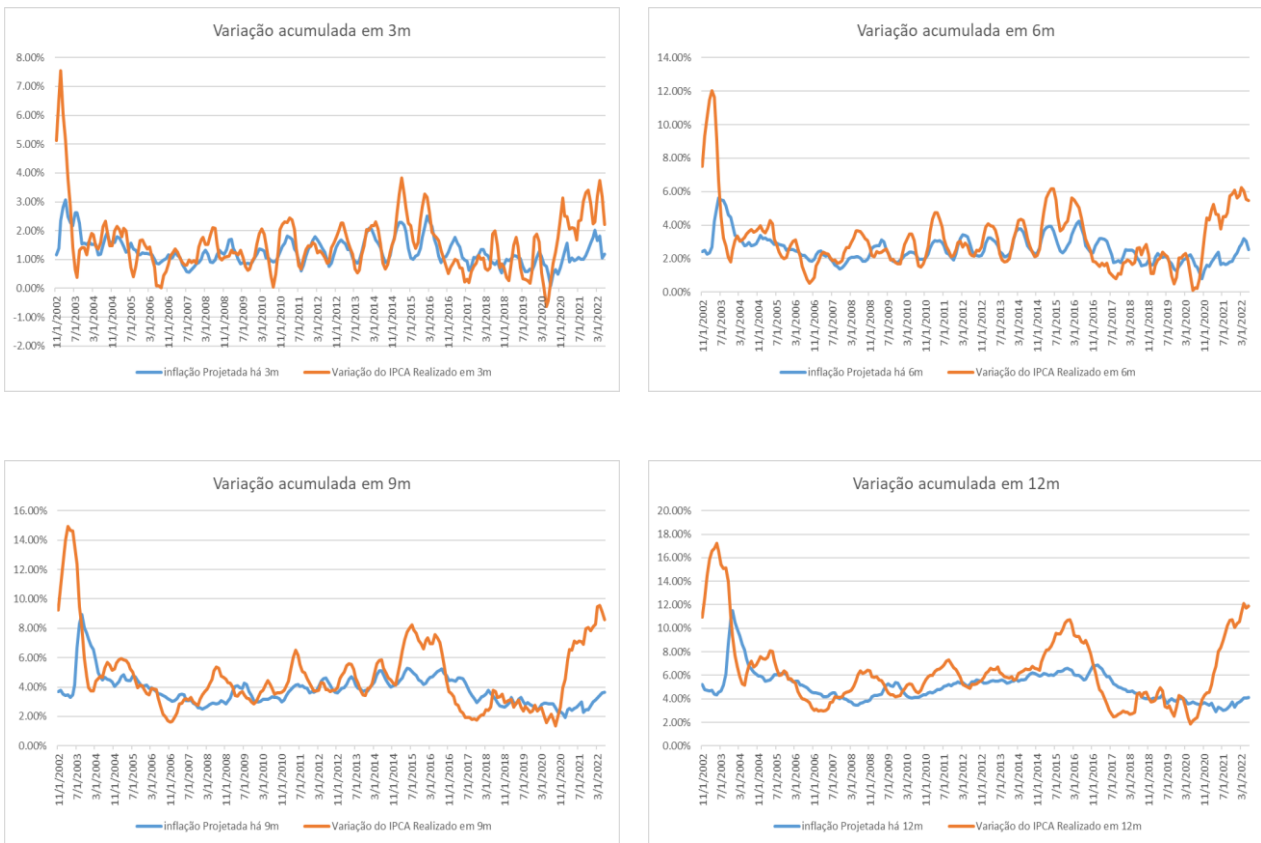
Para a realização do trabalho proposto, buscou-se utilizar as bases de dados do BCB. O Apêndice A contém, de forma detalhada, instruções de como foram montadas as tabelas que serão apresentadas nessa seção. Basicamente, utilizou-se os dados e as médias das previsões do Focus mensalizadas. Com elas foram criados horizontes móveis de tempo: três, seis, nove e doze meses à frente, com o acúmulo composto da inflação ocorrida e prevista, dependendo do caso.

Os gráficos abaixo³ mostram as comparações simples das inflação em três, seis, nove e doze meses com suas previsões de três, seis, nove e doze meses atrás, respectivamente.

³ A fim de organizar a base de dados que será utilizada, recorreu-se ao pacote do R chamado RBCB. O desenvolvedor do pacote define a biblioteca como sendo: “Uma interface para estruturar as informações fornecidas pelo Banco Central do Brasil. Este pacote faz interface com os web services do Banco Central do Brasil para fornecer dados já formatados nas estruturas de dados do R.” em tradução livre. Com apenas uma linha de comando, o pacote devolve a série mensal do IPCA para o período especificado e as previsões do mercado para a inflação. De posse dessas séries, que foram exportadas para o Excel, pôde-se construir uma base de dados que suportasse o estudo.



Figura 1: Gráficos da inflação




Fonte: Elaboração própria

Observa-se nos gráficos acima a existência de uma sazonalidade no comportamento da inflação, em especial para três e seis meses. A princípio, optou-se por tratar essa sazonalidade antes da análise das séries. Ocorre que essa decisão incluiu um viés a favor do aleatório, pois os componentes sazonais das séries realizadas são diferentes dos componentes das séries projetadas.

Para ilustrar o problema encontrado, utiliza-se os gráficos abaixo com as médias dos meses para cada uma das 8 séries temporais a serem utilizadas no estudo:

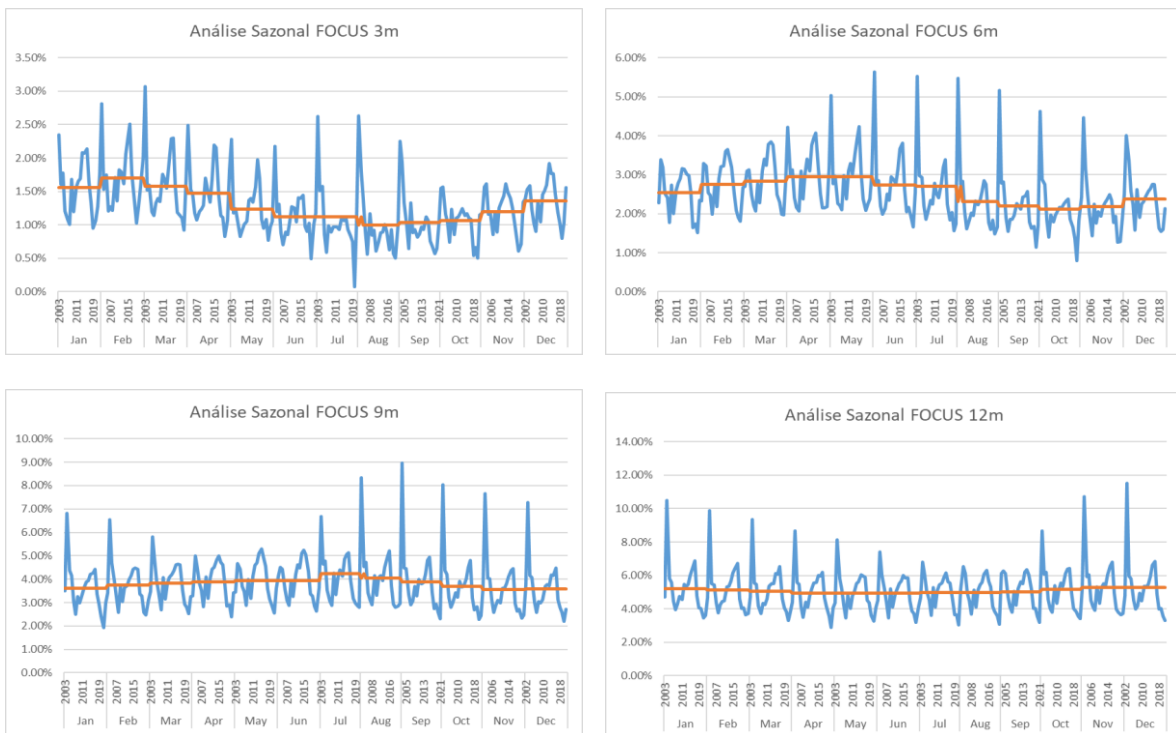
Figura 2: Gráficos da inflação por mês



Fonte: Elaboração própria

Séries Projetadas pelo FOCUS:


Figura 3: Gráficos da média de inflação das projeções do Focus para o IPCA por mês



Fonte: Elaboração própria

Comparativo entre as sazonalidades encontradas:

Figura 4: Gráficos comparativos das médias da inflação por mês e das projeções do Focus para a inflação por mês



Fonte: Elaboração própria

O viés da análise surge no momento em que se propõe encontrar valores aleatórios com base nas características das séries realizadas, e não se mostra justa a comparação entre números corrigidos por sazonalidades diferentes.

Por isso, a análise das séries restou realizada sem o tratamento de sazonalidade para análise de estacionaridade e comparações. Dessa forma, executou-se análises das séries temporais⁴, como forma de assegurar que se trata de uma série que não é na verdade um passeio aleatório, ou seja, trata-se de um conjunto de séries estacionárias.

⁴ Foram utilizados os Softwares Eviews e Jmulti.



5



5

ANÁLISE DOS RESULTADOS

A Tabela 1 apresenta resultados dos testes de raízes unitárias para todas as séries estudadas no presente trabalho. Para tanto, foram utilizados modelos de testagem com e sem quebra estrutural. O leitor mais atento notará que é possível afirmar que todas as séries são estacionárias em nível, ou $I(0)$. Até a série da inflação realizada em doze meses pode ser descrita, com significância de 10%, como uma série estacionária em nível, com quebra de tendência em dezembro de 2003, pelo teste de Vogelsang e Perron (1998).

Outro ponto que vale menção é que, conforme era esperado, ao analisar as quebras sugeridas pelos critérios de Akaike modificado e Hannan-Quinn, encontra-se três momentos econômicos interessantes da história recente do Brasil:

Primeiro, os seis a nove meses do primeiro mandato do presidente Lula. Um momento de instabilidade antecedeu a posse de Lula em 2003, causando depreciação cambial e aumento da inflação em 2002 e início de 2003. Naquele momento o próprio Banco Central chegou a pedir revisões das metas de inflação e sinalizou para a dificuldade de atingimento destas.

Depois, aparece com frequência o período de meados de 2018. Esse período foi marcado pela greve dos caminhoneiros no governo do presidente Michel Temer. O choque de oferta de produtos e a alta demanda naquele período fez os preços subirem de forma inesperada. Com certeza foi um evento exógeno à série temporal testada que causou impactos no seu desenrolar.

Por último, a pandemia de COVID-19 no início dos anos 2020. A Pandemia também causou um choque de oferta, contudo agora de forma global. Restou por causar inflação em muitas economias e não foi diferente aqui no Brasil. Essa perturbação foi apanhada pelos modelos econométricos utilizados.

Tabela 1 – Resultado dos testes de raízes unitárias (2002 a 2022)

Variáveis	Modelo	Sem quebra estrutural			Com quebra estrutural endógena (data da quebra é desconhecida)					
		ADF^{GLS}	\overline{MZ}_t^{GLS}	Lags	Vogelsang e Perron (1998)			Saikkonen e Lütkepohl (2002)		
					Tipo de Modelo	Data da Quebra	Estatística de Teste	Tipo de Modelo	Data da Quebra	Estatística de Teste
$InflaçãoR_t^{3m}$	C	-0,67	-0,10	12	<i>Innovation outlier</i>	2003:02	-5,82 ^(a) (0 lag)	<i>impulse dummy</i>	2018:05	-2,49 (10 lags)
$InflaçãoR_t^{3m}$	C,T	-1,13	-0,81	12	<i>Innovation outlier</i>	2003:03	-5,27 ^(b) (0 lag)	<i>exponential shift</i>	2018:06	-2,28 (10 lags)
$InflaçãoR_t^{3m}$	T	-	-	-	<i>Innovation outlier</i>	2003:04	-6,73 ^(a) (0 lag)	<i>rational shift</i>	2018:06	-2,71 ^(c) (10 lags)
$InflaçãoP_t^{3m}$	C	-3,52 ^(a)	-7,23 ^(c)	12	<i>Innovation outlier</i>	2003:08	-5,26 ^(b) (0 lag)	<i>impulse dummy</i>	2020:07	-2,88 ^(c) (12 lags)
$InflaçãoP_t^{3m}$	C,T	-3,49 ^(a)	-7,74	12	<i>Innovation outlier</i>	2003:08	-4,97 ^(c) (0 lag)	<i>exponential shift</i>	2020:08	-2,43 (12 lags)
$InflaçãoP_t^{3m}$	T	-	-	-	<i>Innovation outlier</i>	2004:01	-5,18 ^(a) (0 lag)	<i>rational shift</i>	2020:08	-2,17 (12 lags)

Variáveis	Modelo	Sem quebra estrutural			Com quebra estrutural endógena (data da quebra é desconhecida)					
		ADF^{GLS}	\overline{MZ}_t^{GLS}	Lags	Vogelsang e Perron (1998)			Saikkonen e Lütkepohl (2002)		
					Tipo de Modelo	Data da Quebra	Estatística de Teste	Tipo de Modelo	Data da Quebra	Estatística de Teste
$InflaçãoR_t^{6m}$	C	-0,78	-0,58	12	<i>Innovation outlier</i>	2003:04	-6,22 ^(a) (0 lag)	<i>impulse dummy</i>	2021:05	-3,03 ^(b) (7 lags)
$InflaçãoR_t^{6m}$	C,T	-1,08	-1,39	12	<i>Innovation outlier</i>	2003:04	-6,05 ^(a) (0 lag)	<i>exponential shift</i>	2021:06	-3,04 ^(b) (7 lags)
$InflaçãoR_t^{6m}$	T	-	-	-	<i>Innovation outlier</i>	2003:07	-6,07 ^(a) (0 lag)	<i>rational shift</i>	2021:06	-2,79 ^(c) (7 lags)
$InflaçãoP_t^{6m}$	C	-2,59 ^(a)	-4,12	8	<i>Innovation outlier</i>	2003:11	-3,98 (0 lag)	<i>impulse dummy</i>	2021:05	-2,67 ^(c) (6 lags)
$InflaçãoP_t^{6m}$	C,T	-2,58	-4,29	8	<i>Innovation outlier</i>	2003:08	-4,47 (0 lag)	<i>exponential shift</i>	2021:06	-2,72 ^(c) (6 lags)
$InflaçãoP_t^{6m}$	T	-	-	-	<i>Innovation outlier</i>	2004:05	-3,66 (0 lag)	<i>rational shift</i>	2021:06	-2,97 ^(b) (6 lags)
$InflaçãoR_t^{9m}$	C	-1,35	-4,25	10	<i>Innovation outlier</i>	2003:05	-5,14 ^(b) (0 lag)	<i>impulse dummy</i>	2021:09	-3,05 ^(b) (10 lags)

Variáveis	Modelo	Sem quebra estrutural			Com quebra estrutural endógena (data da quebra é desconhecida)					
		ADF^{GLS}	\overline{MZ}_t^{GLS}	Lags	Vogelsang e Perron (1998)			Saikkonen e Lütkepohl (2002)		
					Tipo de Modelo	Data da Quebra	Estatística de Teste	Tipo de Modelo	Data da Quebra	Estatística de Teste
$InflaçãoR_t^{9m}$	C,T	-2,11	-13,55	10	<i>Innovation outlier</i>	2003:05	-4,79 (0 lag)	<i>exponential shift</i>	2018:06	-3,17 ^(b) (10 lags)
$InflaçãoR_t^{9m}$	T	-	-	-	<i>Innovation outlier</i>	2003:09	-5,39 ^(a) (0 lag)	<i>rational shift</i>	2018:06	-3,04 ^(b) (10 lags)
$InflaçãoP_t^{9m}$	C	-3,97 ^(a)	-3,65	10	<i>Innovation outlier</i>	2010:11	-3,96 (9 lags)	<i>impulse dummy</i>	2021:08	-4,41 ^(a) (1 lag)
$InflaçãoP_t^{9m}$	C,T	-3,96 ^(a)	-3,85	10	<i>Innovation outlier</i>	2003:11	-4,53 (0 lag)	<i>exponential shift</i>	2021:09	-4,46 ^(a) (1 lag)
$InflaçãoP_t^{9m}$	T	-	-	-	<i>Innovation outlier</i>	2015:09	-3,43 (9 lags)	<i>rational shift</i>	2021:09	-4,45 ^(a) (1 lag)
$InflaçãoR_t^{12m}$	C	-0,88	-1,20	12	<i>Innovation outlier</i>	2003:09	-3,78 (0 lag)	<i>impulse dummy</i>	2018:05	-1,02 (12 lags)
$InflaçãoR_t^{12m}$	C,T	-0,77	-0,98	12	<i>Innovation outlier</i>	2003:05	-3,43 (0 lag)	<i>exponential shift</i>	2018:06	-1,31 (12 lags)

Variáveis	Modelo	Sem quebra estrutural			Com quebra estrutural endógena (data da quebra é desconhecida)					
		ADF^{GLS}	\overline{MZ}_t^{GLS}	Lags	Vogelsang e Perron (1998)			Saikkonen e Lütkepohl (2002)		
					Tipo de Modelo	Data da Quebra	Estatística de Teste	Tipo de Modelo	Data da Quebra	Estatística de Teste
$InflaçãoR_t^{12m}$	T	-	-	-	<i>Innovation outlier</i>	2003:12	-4,38 ^(c) (0 lag)	<i>rational shift</i>	2018:06	-1,46 (12 lags)
$\Delta InflaçãoR_t^{12m}$	C	-1,58	-0,54	12	<i>Innovation outlier</i>	2003:11	-8,67 ^(a) (0 lag)	<i>impulse dummy</i>	2018:06	-5,53 ^(a) (12 lags)
$\Delta InflaçãoR_t^{12m}$	C,T	-3,12 ^(b)	-2,65	12	<i>Innovation outlier</i>	2004:01	-9,48 ^(a) (0 lag)	<i>exponential shift</i>	2020:01	-2,42 (12 lags)
$\Delta InflaçãoR_t^{12m}$	T	-	-	-	<i>Innovation outlier</i>	2003:04	-8,37 ^(a) (0 lag)	<i>rational shift</i>	2018:06	-5,48 ^(a) (12 lags)
$InflaçãoP_t^{12m}$	C	-2,78 ^(a)	-4,45	11	<i>Innovation outlier</i>	2017:06	-4,55 (12 lags)	<i>impulse dummy</i>	2021:12	-3,87 ^(a) (1 lag)
$InflaçãoP_t^{12m}$	C,T	-2,97 ^(b)	-5,31	11	<i>Innovation outlier</i>	2003:12	-4,42 (0 lag)	<i>exponential shift</i>	2021:12	-3,99 ^(a) (1 lag)
$InflaçãoP_t^{12m}$	T	-	-	-	<i>Innovation outlier</i>	2004:02	-3,89 (11 lags)	<i>rational shift</i>	2021:12	-4,01 ^(a) (1 lag)

Variáveis	Modelo	Sem quebra estrutural			Com quebra estrutural endógena (data da quebra é desconhecida)					
		ADF^{GLS}	\overline{MZ}_t^{GLS}	Lags	Vogelsang e Perron (1998)			Saikkonen e Lütkepohl (2002)		
					Tipo de Modelo	Data da Quebra	Estatística de Teste	Tipo de Modelo	Data da Quebra	Estatística de Teste
$\Delta Inflação P_t^{12m}$	C	-2,89(a)	-1,52	12	<i>Innovation outlier</i>	2003:10	-11,05 ^(a) (0 lag)	<i>impulse dummy</i>	2021:12	-6,58 ^(a) (6 lags)
$\Delta Inflação P_t^{12m}$	C,T	-6,46(a)	-7,86	12	<i>Innovation outlier</i>	2003:10	-11,43 ^(a) (0 lag)	<i>exponential shift</i>	2021:05	-4,95 ^(a) (6 lags)
$\Delta Inflação P_t^{12m}$	T	-	-	-	<i>Innovation outlier</i>	2004:04	-7,90 ^(a) (2 lags)	<i>rational shift</i>	2021:05	-6,72 ^(a) (6 lags)

Fonte: elaboração própria. Uso dos softwares econométricos Eviews e JMULTI.

Nota:

1 – “Lags” significa defasagens. Tipos de modelo: “C” significa constante; “T” significa tendência determinística. Contagem inicial máxima de 5 defasagens. Note que (a), (b) e (c) indicam que os coeficientes estimados são estatisticamente significantes ou rejeição da hipótese nula ao nível de significância estatística de 1%, 5% e 10%, respectivamente. Observações mensais incluídas: 236 (amostra: Nov/2002 a Jun/2022).

2 – Os valores críticos do teste ADF^{GLS} são (Elliot, Rothenberg e Stock, 1996): (i) modelo com constante: -2,67 (1%), -1,96 (5%) e -1,60 (10%). (ii) modelo com constante e tendência determinística: -3,77 (1%), -3,19 (5%) e -2,89 (10%). Seleção do número ótimo de defasagens por meio do critério de informação de Akaike modificado.

3 – Os valores críticos assintóticos do teste $\overline{MZ}_\alpha^{GLS}$ são (Ng e Perron, 2001, Tabela 1): (i) modelo com constante: -2,58 (1%), -1,98(5%) e -1,62 (10%); (ii) modelo com constante e tendência determinística: -3,42 (1%), -2,91 (5%) e -2,62 (10%).

Método de estimação espectral: AR GLS-*detrended*. Seleção do número ótimo de defasagens por meio do critério de informação de Akaike modificado.

4 – Os valores críticos do teste de Vogelsang e Perron (1998) são: (i) modelo com constante e tendência/quebra de intercepto: -5,35 (1%), -4,86 (5%), e -4,61 (10%); (ii) modelo com constante e tendência determinística/quebra de intercepto e de tendência: -5,72 (1%), -5,18 (5%), e -4,89 (10%). (iii) modelo com constante e tendência determinística/quebra de tendência: -5,06 (1%), -4,52 (5%), e -4,26 (10%). Tipos de quebra: *innovational outlier* e *additive outlier*. Seleção da quebra estrutural: estatística *t* de Dickey-Fuller minimizada. Seleção do número ótimo de defasagens: Critério de Informação de Akaike modificado.

5 – Os valores críticos do teste de Saikkonen-Lütkepohl são (Lanne *et al.*, 2002): (i) modelo com constante: -3,48 (1%), -2,88 (5%), e -2,58 (10%); (ii) modelo com constante e tendência determinística: - 3,55 (1%), -3,03 (5%), e -2,76 (10%). Tipos de quebra estrutural: *Rational Shift*, *Exponential Shift* e *Impulse Shift*, com critério de informação de Hannan-Quinn.

Tem-se, portanto, que as séries selecionadas são estacionárias em nível. Dessa forma, é válida a afirmação que as séries de inflação que se apresentam têm na verdade média e variância constantes, porém com algumas quebras estruturais. Essas quebras inseriram momentos de aumento da volatilidade ou da variância do ruído. Outro ponto que merece destaque, conforme demonstrado acima, é o fato de haver uma sazonalidade implícita, principalmente nas séries de horizonte mais curto (3 e 6 meses).

Como implicação direta da afirmação anterior, tem-se que as séries podem ser descritas por:

$$Y_t = X_0 + \varepsilon_t \quad (15)$$

Onde Y_t é a inflação medida no período t e ε_t é um erro aleatório.

Apenas para demonstrar o efeito sazonal, Tabela 2 abaixo mostra as médias para cada mês em cada série da inflação entre novembro de 2002 e junho de 2022. Note que essas médias não foram utilizadas para o cálculo das simulações, pois incluem dados que futuros para o início da série. Conforme já mencionado e será possível analisar nos gráficos mais adiante, para o cálculo da sazonalidade das simulações foram utilizados apenas dados até aquele momento que está se calculando.

Tabela 2: Médias mensais para cada série.

Mês	Média (\bar{x}_m)			
	Inflação 3m (\bar{x}_m^{3m}) (%)	Inflação 6m (\bar{x}_m^{6m}) (%)	Inflação 9m (\bar{x}_m^{9m}) (%)	Inflação 12m (\bar{x}_m^{12m}) (%)
Jan	2,06%	3,38%	4,53%	6,31%
Fev	2,09%	3,76%	4,79%	6,35%
Mar	1,97%	3,95%	5,12%	6,41%
Abr	1,80%	3,90%	5,26%	6,42%
Mai	1,56%	3,69%	5,39%	6,44%
Jun	1,26%	3,26%	5,26%	6,45%

Jul	1,06%	2,78%	4,89%	6,15%
Ago	0,92%	2,41%	4,54%	6,16%
Set	1,04%	2,26%	4,22%	6,19%
Out	1,22%	2,30%	4,03%	6,18%
Nov	1,63%	2,64%	4,16%	6,30%
Dez	1,92%	3,07%	4,33%	6,30%

Fonte: Elaboração própria

Primeiramente, cumpre ressaltar que para a análise dos resultados serão considerados dois cenários. O primeiro com 1.000 e o segundo com 100.000 simulações para cada mês em cada horizonte de tempo. Estes dois cenários foram escolhidos por uma limitação computacional.

Como se julga importante guardar o registro dos resultados individuais para cada simulação feita em cada mês e cada cenário, se houvesse a tentativa de guardar o registro para 100.000 simulações restaria uma quantidade praticamente intratável de dados, pois seriam 100.000 registros para cada um dos 236 meses, em quatro séries temporais, ou 94.400.000 registros.

Ocorre que os resultados não tiveram grandes diferenças e serão apresentados na Tabela 3. De forma sucinta, traz as comparações para cada um dos 236 meses contidos na série temporal que está sendo estudada. Para cada horizonte de tempo foram contados os meses em que o aleatório obteve mais sucesso ao prever a inflação que iria ocorrer em comparação à média dos números do Boletim Focus, e vice-versa.

Então, como exemplo, pode-se pegar o primeiro resultado: 75 meses. Que dizer que em 75 dos 236 meses analisados, mais de 500 das 1000 simulações aleatórias, estiveram mais próximas do resultado oficial da inflação que a previsão média do mercado.

Tabela 3: Resultados das simulações⁵.

Cenário	Meses	> Eficácia com 1.000 simulações		> Eficácia com 100.000 simulações	
		Simulação Proposta	Previsão do Mercado	Simulação Proposta	Previsão do Mercado
3 meses	236	75 meses	161 meses	82 meses	154 meses
6 meses	236	84 meses	152 meses	87 meses	149 meses
9 meses	236	101 meses	135 meses	101 meses	135 meses
12 meses	236	107 meses	129 meses	110 meses	126 meses


Fonte: Elaboração própria

As pequenas diferenças são causadas por meses onde o resultado das simulações tem eficácia muito próxima dos 50%. Porém ocorre que essa análise não é completa e pode ser aprofundada. Há a necessidade de se avaliar, por exemplo, quão melhores foram as estimações em relação as simulações e vice-versa para cada mês.

Então, ao se analisar os dados obtidos com mil simulações, pôde-se construir gráficos que apresentam a inflação medida no horizonte de tempo escolhido, a inflação esperada pela média do mercado financeiro e o aleatório calculado dentro do modelo proposto neste estudo (sendo este último apresentado em seu valor médio, máximo e mínimo para as 1.000 simulações)

Note que para três meses há uma frequência bem definida e o nível das séries também é muito bem-comportado. Não à toa, os valores simulados de forma aleatória estão tão próximos dos valores projetados e realizados.


⁵ Elaborado no R Studio

Figura 4: Comparações para o cenário de três meses

Fonte: Elaboração própria

Para seis meses, assim como o de três, pode-se ainda ver um efeito sazonal bem demarcado, principalmente nos momentos de menor volatilidade. Importante notar que os dados do Focus estão suavizados em relação a amplitude da inflação efetivamente medida. Ou seja, a capacidade de prever a inflação em momentos de instabilidade é bem questionável.


Figura 5: Comparações para o cenário de seis meses



Fonte: Elaboração própria

O efeito de subestimação da amplitude da inflação medida, mencionado para os seis meses, aparece de forma mais acentuada para nove meses. Isso se dá por dois motivos, basicamente: *i.* o lapso temporal da estimativa e do ocorrido é maior, ou seja, demandaria uma poder de previsão maior, e; *ii.* Quanto maior o intervalo de tempo que está se medindo, maior o efeito da tendência e menor o efeito de volatilidade no indicador.


Figura 6: Comparações para o cenário de nove meses



Fonte: Elaboração própria

Para a série de doze meses fica gritante, além das duas características mencionadas para nove meses, a quase inexistência de uma sazonalidade marcante como existe nas outras séries.

Figura 7: Comparações para o cenário de doze meses



Fonte: Elaboração própria

Pode-se observar que grande parte da informação do Focus é a sazonalidade da série. As linhas em azul claro são os limites da simulação e elas se separam ou se aproximam da média (em vermelho) de acordo com a variância que antecedeu os três meses anteriores ao lapso temporal que se está estudando.

Outra informação relevante que se pôde retirar das simulações de 100.000 é referente à quão melhor ou pior em cada mês se mostrou a simulação em relação ao projetado. Os gráficos abaixo mostram o percentual de vezes em que a simulação bateu o Focus para cada mês em cada um dos cenários.


A montagem desses gráficos torna mais direto o entendimento do que está acontecendo. Pode-se verificar neles já a comparação entre as distâncias entre o que era previsto pelo mercado e os resultados das gaussianas propostas, os dois em relação a inflação que seria medida no futuro. Quer dizer, para cada mês foram analisadas as diferenças entre a inflação medida e as previsões do Focus além das diferenças entre a inflação medida e os cenários gerados pela simulação.

Com essas comparações tabuladas, se torna possível trazer de forma clara a informação do percentual de vezes que para cada mês e cenário a simulação esteve mais próxima da inflação que viria a ser medida pelo IBGE.

Essa informação, que será apresentada nos próximos gráficos, é bem mais relevante que a apresentada na Tabela 3, pois, além de informar quantos meses o aleatório foi mais eficiente, também mostra que, mesmo quando a média das previsões foi mais efetiva que mais de 50% das simulações aleatórias, ainda assim houve casos em que dentro das simulações algumas eram mais eficientes que o número extraído do Focus.

Basicamente, serão apresentados para cada horizonte de tempo: três, seis, nove e doze meses o percentual de acerto dentro de cada mês. A área em azul escuro representa o percentual de vezes que a simulação aleatória esteve mais perto do resultado verificado e a área em azul claro é justamente o oposto, ou o Focus estando mais próximo da inflação medida.

Figura 8: Gráfico com os resultados para o cenário de três meses



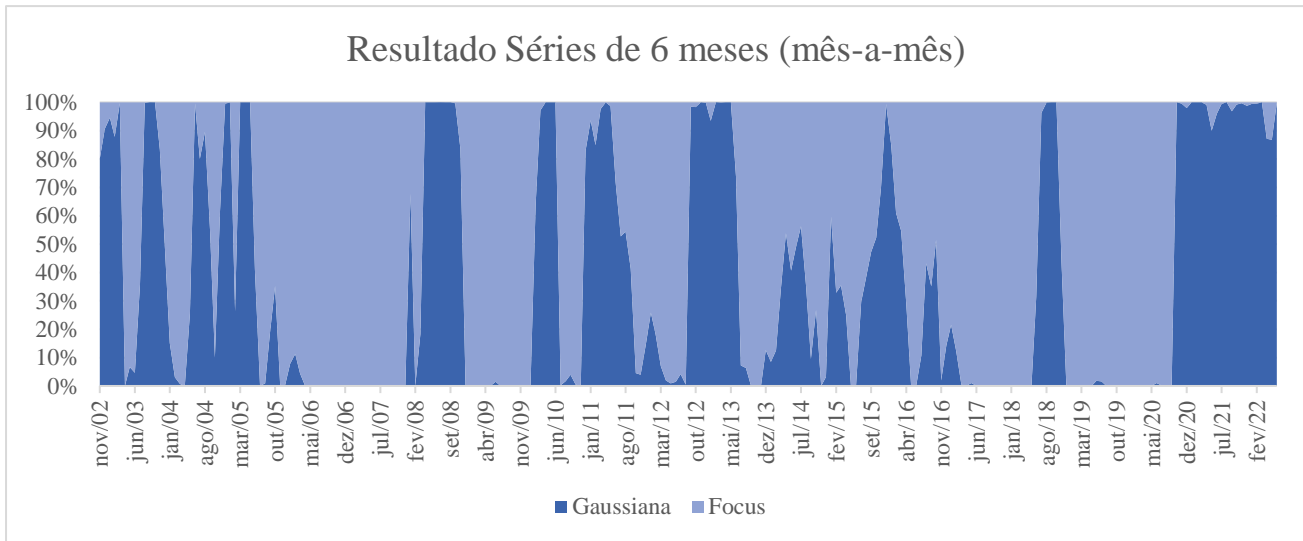
Fonte: Elaboração própria

Vê-se que as previsões do Focus erram mais, ou ficam mais distantes, justamente nos momentos em que ocorrem os momentos mais turbulentos da série de inflação, e justamente nesses momentos o componente aleatório cresce. Este comportamento pode ser analisado nos dois sentidos.

Ora o mercado superdimensiona momentos de turbulência, como por exemplo previu nos primeiros meses de 2003 uma inflação maior do que a efetivamente medida no segundo e terceiro trimestre de 2003, nesse momento da história do Brasil estava se vivendo os primeiros meses de governo Lula (Lula1, 2003-2006), e havia uma insegurança sobre a condução da economia brasileira.

Por outro lado, por vezes ignora ou subdimensiona crises reais, como pode ser observado durante os anos de 2014 e 2015, quando a inflação superou as previsões do mercado, ou ainda mais recentemente, durante a crise sanitária de COVID-19, onde o mercado não foi capaz de antever, não só a inflação baixa do início da pandemia causado pela desaceleração da economia, mas também a inflação que se seguiu no período seguinte, possivelmente causada por um choque de oferta com a interrupção das cadeias produtivas.


Figura 9: Gráfico com os resultados para o cenário de seis meses



Fonte: Elaboração própria

Quando se aumenta o lapso temporal, além de se poder dividir de forma mais estável o que se pode chamar de momentos de dominância do Focus sobre o aleatório (quando o Focus está mais próximo da inflação efetivamente medida), também se nota que a linha do aleatório praticamente some. Isso ocorre, por ser o efeito da tendência muito maior que o efeito da volatilidade para intervalos maiores de tempo.

Ora, esse comportamento inclusive tende a aumentar com o incremento do lapso temporal. Além disso, como aumenta também o tempo em que a previsão foi registrada (antes era três meses e agora seis), existe um maior lapso temporal até a aparição de um choque nas previsões.

Figura 10: Gráfico com os resultados para o cenário de nove meses


Fonte: Elaboração própria

Já com 9 meses de antecedência fica claro que o mercado simplesmente não consegue prever momentos de turbulência, essa afirmação depreendida da análise do gráfico acima, fica nítida por não ter previsto turbulências em torno do escândalo do mensalão 2004-2005, crise do *sub-prime* 2008 e 2009, a crise europeia de 2011 e 2012, nem a inflação causada na tentativa de manter a economia brasileira aquecida nos anos de 2014 e 2015, depois não acertou o impacto das medidas tomadas no governo Michel Temer, e por fim, agora com a pandemia viu suas previsões estarem fora seria medido efetivamente.

Algumas dessas crises aumentaram sobremaneira a percepção de risco dos investidores mundo afora, pressionando a inflação pelo canal do câmbio. Outras foram crises internas. Mas certamente elas não foram percebidas com uma antecedência de nove meses.

Para doze meses, o cenário descrito anteriormente é ainda mais gravoso, com apenas poucos meses onde há uma divisão entre simulações e Focus que não seja 100% para um lado ou para o outro. Esse comportamento pode ser verificado nas Figuras de 4 a 7 de forma mais detalhada.


Figura 11: Gráfico com os resultados para o cenário de doze meses



Fonte: Elaboração própria

Assim como o resultado com 1.000 simulações, o resultado de 100.000 simulações apresentou um desempenho pior que as projeções do mercado. E esse resultado era esperado, pelo senso comum. Embora melhor, o resultado ficou muito aquém do razoável, principalmente para os intervalos de tempo maiores. Note que a média das previsões do mercado é apenas 33% melhor que o aleatório para nove meses e para doze meses é apenas 14,5% melhor. Abaixo um gráfico com os resultados obtidos.

Figura 12: Gráfico comparativo Aleatório versus Projeções do Mercado



Fonte: Elaboração própria

Isso quer dizer que em 46,6% (110 meses de 236 testados) o resultado da simulação aleatória esteve mais próximo da inflação efetivamente medida que a média das projeções feitas pelo Mercado e compiladas pelo BCB no relatório Focus em mais de 50% das simulações para o mês, quando se analisa os resultados para doze meses.

Note, no entanto, que o resultado apresentado acima não considera todas as comparações realizadas. Mostra, tão somente, a quantidade de meses na qual um dos dois acertou mais que o outro. Ocorre que nos meses em que o aleatório acertou mais de 50%, não necessariamente acertou 100%, como mostram as Figuras 9 a 12. Para uma correta análise do poder de previsão do Boletim Focus, há de se realizar testes de hipótese⁶ que irão ajudar na quantificação dos resultados obtidos.

Com o teste de hipótese, há a possibilidade de se chegar a um número objetivo. Esse número representa, dentro de um intervalo de confiança, o quão confiáveis são os números contidos no relatório Focus. Os resultados dos testes estão agrupados na Tabela 4 abaixo:

Tabela 4: Resultados dos testes de hipóteses.

Série	1%	5%	10%
3 meses	59,32%	61,00%	61,88%
6 meses	55,54%	57,44%	58,45%
9 meses	51,79%	53,84%	54,93%
12 meses	47,35%	49,47%	50,60%

Fonte: Elaboração própria

As informações na tabela acima apresentam os valores a partir dos quais a hipótese nula H_0 (o Focus acerta mais de X% das comparações) passa a ser rejeitada para um nível de significância de 1%, 5% ou 10%, conforme a coluna. Traduzindo a Tabela 4 para sentenças, pode-se afirmar o seguinte:

⁶ Gerados no R e suas saídas estão representadas no Apêndice B

Com base nos resultados apresentados acima, para o cenário de três meses, é possível afirmar:

- i. Com 10% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 61,88% das suas projeções médias;
- ii. Com 5% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 61,00% das suas projeções médias;
- iii. Com 1% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 59,32% das suas projeções médias;

Com base nos resultados apresentados acima, para o cenário de seis meses, é possível afirmar:

- i. Com 10% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 58,45% das suas projeções médias;
- ii. Com 5% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 57,44% das suas projeções médias;
- iii. Com 1% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 55,54% das suas projeções médias;

Com base nos resultados apresentados acima, para o cenário de nove meses, é possível afirmar:

- i. Com 10% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 54,93% das suas projeções médias;
- ii. Com 5% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 53,84% das suas projeções médias;
- iii. Com 1% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 51,79% das suas projeções médias;


Com base nos resultados apresentados acima, para o cenário de doze meses, é possível afirmar:

- iv. Com 10% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 50,60% das suas projeções médias;
- v. Com 5% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 49,47% das suas projeções médias;
- vi. Com 1% de certeza, não é possível afirmar que o Relatório Focus acerte mais de 47,35% das suas projeções médias;

Há ainda uma outra questão que concerne a capacidade preditiva do Focus para momentos de turbulência no mercado, ou seja,

há a capacidade de antever aqueles momentos em que a inflação medida ultrapassará as bandas definidas pelo CMN? A figura abaixo foi gerada de forma a apresentar as taxas anuais de inflação em dezembro de cada ano.

Figura 13: Gráfico com os números de dezembro e bandas CMN



Fonte: Elaboração própria

Tomando não apenas o resultado de dezembro de cada ano, mas o resultado anualizado de todos os meses, a variação do IPCA esteve fora da meta de inflação por 95 meses dos 236. A média do Focus só foi capaz de prever apenas 6 desses com antecedência de 12 meses.



6

6

CONSIDERAÇÕES FINAIS E IMPLICAÇÕES DE POLÍTICAS

O presente estudo teve por objetivo geral analisar o desempenho das instituições cadastradas no Sistema Focus, no que se refere às previsões da taxa de inflação segundo o IPCA. Para alcançar essa finalidade, foi considerada a abordagem metodológica que envolve a geração de "n" números aleatórios com média e desvio padrão dados pelos termos anteriores da série de inflação e compará-los com a média das previsões feitas pelo mercado e apresentadas pelo BCB no Focus.

Como foi demonstrado, com um nível de significância de 5%, pode-se afirmar que os dados do Focus acertam mais que 61% para o curto prazo (3 meses) e apenas 49,5% para horizontes mais longos (12 meses). Esta afirmação está baseada nos dados disponibilizados pelo BCB e pelo método descrito e implementado neste trabalho.

Contudo, conforme alertado na seção de revisão bibliográfica, não há como se ter certeza de que as previsões reportadas pelas instituições financeiras sejam de fato as suas melhores previsões. Nem há, ao menos, como garantir que não haja uma tentativa delas de influenciar a política a ser tomada pela autoridade monetária.

Do ponto de vista de risco, já que se pretendia utilizar as previsões como um indicador, fica claro que os números do Focus não deveriam ser utilizados para esse fim: seja pela baixa certeza que trazem consigo, seja pelo fato de que, desde a efetiva implementação das metas de inflação em 2002 houve o rompimento da banda por cinco oportunidades e o Focus acertou apenas duas (além de ter previsto uma que não ocorreu de fato).

Conquanto não pareça haver uma capacidade preditiva forte o suficiente para justificar a utilização dos dados do mercado como um indicador de risco (vide Figura 13), não quer dizer de forma alguma que essas previsões devam ser ignoradas. Pelo contrário, as previsões do Focus nos fornecem uma medida muito apurada de quão ancoradas estão as expectativas do mercado acerca da política monetária.

Só isso seria suficiente para justificar o trabalho executado, contudo, o presente estudo foi capaz de evidenciar que há espaço para melhorias dos modelos de previsão e o fomento a análises e geração de métodos mais precisos são de extremo valor para o BCB.

De toda forma, o objetivo inicial do trabalho foi alcançado. Embora, os resultados se mostraram diferente do que se imaginava, a dissertação representa um avanço no entendimento dos números contidos no relatório Focus. Estes que devem ser entendidos não como previsões para a inflação, mas como expectativas parciais com capacidade de predição limitada.

Visando estudos futuros, pode-se pensar em alguns próximos passos, como a identificação de sinais de maiores incertezas nas previsões, tal como uma medida de dispersão do conjunto de previsões ou mesmo a distribuição dessas previsões (por exemplo, pode haver uma distribuição bimodal quando houver uma incerteza grande do que se espera para daqui a 12 meses). A construção de variáveis *dummies* para mensurar essas incertezas pode auxiliar a tomada de decisão do BCB se comprovada um poder de previsão maior.



REFERÊNCIAS

REFERÊNCIAS

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR ISO 31000: Gestão de riscos — Diretrizes**. Rio de Janeiro, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR ISO 31010: Gestão de riscos – Técnicas para o processo de avaliação de riscos**. Rio de Janeiro, 2012.

BAUER, Michael D. et al. Can we rely on market-based inflation forecasts? **FRBSF Economic Letter**, v. 30, p. 1-5, 2015.

BERNANKE, Ben S. et al. Inflation expectations and inflation forecasting. In: **Speech at the Monetary Economics Workshop of the National Bureau of Economic Research Summer Institute**, Cambridge, Massachusetts. 2007.

BRASIL. Controladoria Geral da União; Ministério do Planejamento Orçamento e Gestão. Dispõe sobre controles internos, gestão de riscos e governança no âmbito do Poder Executivo federal. INC nº 1, de 10/05/2016. **Diário Oficial da União**, Brasília, DF, 10 mai. 2016.

CALDEIRA, João F.; FURLANI, Luiz GC. Inflação implícita e o prêmio pelo risco: uma alternativa aos modelos VAR na previsão para o IPCA. **Estudos Econômicos (São Paulo)**, v. 43, p. 627-645, 2013.

CASAGRANDE, Bruno Aguiar; DE ANDRADE MATOS, Richer. Indicadores Macroeconômicos: Desempenho das Projeções do Relatório de Mercado Focus Para o IpcA, Selic e Câmbio. **Caderno PAIC**, v. 17, n. 1, p. 39-59, 2016.

COMMITTEE OF SPONSORING ORGANIZATION OF THE TREADWAY COMMISSION – COSO. **Enterprise Risk Management: Integrating with Strategy and Performance**. Executive Summary. Washington , 2017.

CHERNAVSKY, Emilio. Quão Boas São as Previsões do Relatório Focus/BCB?. **Informações Fipe** n° 374, p. 8, 2011.

CYSNE, Rubens Penha et al. Imposto inflacionário e transferências inflacionárias no Brasil. **EPGE Brazilian School of Economics and Finance-FGV EPGE** (Brazil), 1993.

DE CARVALHO, F.; MINELLA, André. Previsões de Mercado no Brasil: desempenho e determinantes. **Dez Anos de Metas para A Inflação No Brasil**, p. 169, 2009.

DUFOUR, Jean-Marie; TORRÈS, Olivier. Markovian processes, two-sided autoregressions and finite-sample inference for stationary and nonstationary autoregressive processes. **Journal of Econometrics**, v. **99**, n. 2, p. 255-289, 2000.

ECKHARDT, Roger. Stan Ulam, John Von Neumann, and the monte carlo method. **Los Alamos Science**, v. 15, n. 131-136, p. 30, 1987.

EGOROV, Alexei V.; HONG, Yongmiao; LI, Haitao. Validating forecasts of the joint probability density of bond yields: Can affine models beat random walk?. **Journal of Econometrics**, v. **135**, n. 1-2, p. 255-284, 2006.

FERREIRA, Patrícia Mota; LESSA, Márcio Benevides. A ASSERTIVIDADE DAS PROJEÇÕES DOS PRINCIPAIS INDICADORES DO RELATÓRIO FOCUS PARA A ECONOMIA BRASILEIRA NO PERÍODO DE 2012 A 2013. **Revista Eletrônica de Debates em Economia**, v. 3, n. 1, 2015.

HAMILTON, James D. Uncovering financial market expectations of inflation. **Journal of Political Economy**, v. 93, n. 6, p. 1224-1241, 1985.

HOFFMANN, Rodolfo. Desigualdade e pobreza no Brasil no período 1979/97 e a influência da inflação e do salário mínimo. **Economia e Sociedade**, v. 7, n. 2, p. 199-221, 1998.

KILIAN, Lutz; TAYLOR, Mark P. Why is it so difficult to beat the random walk forecast of exchange rates?. **Journal of International Economics**, v. 60, n. 1, p. 85-107, 2003.

LIMA, Elcyon Caiado R.; CÉSPEDES, Brisne J. Vasquez. O desempenho do mercado (Focus) e do BACEN na previsão da inflação: Comparações com modelos lineares univariados. **Boletim de Conjuntura IPEA**, n. 60, p. 75-83, 2003.

MURAT, Luiz Felipe Gomes. **Previsibilidade de variáveis macroeconômicas: um estudo comparativo do grau de acurácia de previsões existentes no boletim Focus**. 2015. Dissertação (Mestrado – Programa de Mestrado Profissional em Economia. Linha de Pesquisa: Finanças e Macroeconomia Aplicadas) – Insper Instituto de Ensino e Pesquisa, São Paulo. 2015

BRASIL. Banco Central do Brasil. **Perguntas frequentes - Expectativas de mercado**, disponível em: <https://www.bcb.gov.br/controleinflacao/faqexpectativa> acessado em 31/03/2022

BRASIL. Banco Central do Brasil. **Relatório Integrado de Gestão do BCB**, disponível em: https://www.bcb.gov.br/content/publicacoes/rig/rig_2020.pdf acessado em 31/03/2022

BRASIL. Banco Central do Brasil. **Sistema Expectativas de Mercado**, disponível em: <https://www3.bcb.gov.br/expectativas2/#/consultas> acessado em 31/03/2022

BRASIL. Tribunal de Contas da União Acórdão nº 2467/2013. Plenário. Relatora: Ministra Anna Arraes. Sessão de 11/09/2013. **Diário Oficial da União**, Brasília, DF, 11 set. 2013.

WEBER, Marcelo. **Inflação futura: uma análise comparativa entre as expectativas do focus e as inflações implícitas nos títulos públicos**. 2011. Dissertação (mestrado profissional) – Escola de Economia de São Paulo. Fundação Getúlio Vargas, São Paulo. 2011



APÊNDICES

APÊNDICES

APÊNDICES

Apêndice A – Instruções detalhadas para obtenção dos dados e construção das tabelas

Para viabilizar o estudo, haverá uma coleta das informações de previsão, que são publicadas no endereço eletrônico do BCB, bem como dos resultados alcançados pelo IPCA. A análise dos dados será realizada no Eviews, Jmulti, R e Excel. As análises das séries serão realizadas no Eviews e Jmulti. O R será utilizado para a realização das simulações de Monte Carlo e o Excel para construção das bases, tabelas e gráficos.

O passo-a-passo para a montagem das tabelas que servirão de Base de Dados para o estudo:

1. Baixar no R, pelo pacote RBCB, os dados do IPCA mês-a-mês com o comando: `DeltaIPCAMensal <- rbcB::get_series(c(IPCA = 433), last = 600);`
2. Selecionar então, no Excel, o período desejado (janeiro de 1995 até junho de 2022);
3. Criar, séries da inflação acumulada em três, seis, nove e doze meses, ainda no excel;
4. Baixar no R, pelo pacote RBCB, os dados das previsões de inflação mês-a-mês com o comando: `BaseFOCUSMensal <- rbcB::get_market_expectations(c("monthly"), c("IPCA"), "1994-01-01");`
5. Criar, séries da inflação projetada acumulada em três, seis, nove e doze meses, ainda no excel;
6. Montar então a base para a comparação desejada no objetivo do trabalho com os seguintes campos:
 - a. Data (mês)
 - b. Previsão para a inflação realizada 3 meses atrás
 - c. Previsão para a inflação realizada 6 meses atrás
 - d. Previsão para a inflação realizada 9 meses atrás
 - e. Previsão para a inflação realizada 12 meses atrás
 - f. Inflação nos últimos 3 meses
 - g. Inflação nos últimos 6 meses
 - h. Inflação nos últimos 9 meses



i. Inflação nos últimos 12 meses



Apêndice B – Resultados dos testes de hipótese

Aqui será apresentada a implementação dos testes de hipóteses propostos em 3.1, além das saídas de cada comando o p-value em negrito representa a estatística “ α ”.

```
> #Testes de hipótese 3m
> t.test(result3m$focus,rep(61879,236),paired=FALSE,alternative =
"greater")#Com 10%
```

Welch Two Sample t-test

```
data: result3m$focus and rep(61879, 236)
t = 1.2847, df = 235, p-value = 0.1001
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
-886.4025    Inf
sample estimates:
mean of x mean of y
64985.17 61879.00
```

```
> t.test(result3m$focus,rep(60995,236),paired=FALSE,alternative =
"greater")#Com 5%
```

Welch Two Sample t-test

```
data: result3m$focus and rep(60995, 236)
t = 1.6504, df = 235, p-value = 0.0501
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
-2.402501    Inf
```


sample estimates:

mean of x mean of y

64985.17 60995.00

```
> t.test(result3m$focus,rep(59323,236),paired=FALSE,alternative =
"greater")#Com 1%
```

Welch Two Sample t-test

data: result3m\$focus and rep(**59323**, 236)

t = 2.3419, df = 235, **p-value = 0.01001**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

1669.597 Inf

sample estimates:

mean of x mean of y

64985.17 59323.00

>

> #Testes de hipótese 6m

```
> t.test(result6m$focus,rep(58449,236),paired=FALSE,alternative =
"greater")#Com 10%
```

Welch Two Sample t-test

data: result6m\$focus and rep(**58449**, 236)

t = 1.2846, df = 235, **p-value = 0.1001**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

-1007.212 Inf

sample estimates:



mean of x mean of y
61976.64 58449.00

```
> t.test(result6m$focus,rep(57442,236),paired=FALSE,alternative =  
"greater")#Com 5%
```

Welch Two Sample t-test

data: result6m\$focus and rep(**57442**, 236)

t = 1.6513, df = 235, **p-value = 0.05001**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

-0.212258 Inf

sample estimates:

mean of x mean of y
61976.64 57442.00

```
> t.test(result6m$focus,rep(55545,236),paired=FALSE,alternative =  
"greater")#Com 1%
```

Welch Two Sample t-test

data: result6m\$focus and rep(**55545**, 236)

t = 2.3421, df = 235, **p-value = 0.01001**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

1896.788 Inf

sample estimates:

mean of x mean of y
61976.64 55545.00



```
>
> #Testes de hipótese 9m
> t.test(result9m$focus,rep(54930,236),paired=FALSE,alternative =
"greater")#Com 10%
```

Welch Two Sample t-test

```
data: result9m$focus and rep(54930, 236)
t = 1.2847, df = 235, p-value = 0.1001
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
-1088.668      Inf
sample estimates:
mean of x mean of y
58744.22 54930.00
```

```
> t.test(result9m$focus,rep(53842,236),paired=FALSE,alternative =
"greater")#Com 5%
```

Welch Two Sample t-test

```
data: result9m$focus and rep(53842, 236)
t = 1.6511, df = 235, p-value = 0.05002
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
-0.6678566      Inf
sample estimates:
mean of x mean of y
58744.22 53842.00
```

```
> t.test(result9m$focus,rep(51791,236),paired=FALSE,alternative =
"greater")#Com 1%
```

Welch Two Sample t-test

```

data: result9m$focus and rep(51791, 236)
t = 2.3419, df = 235, p-value = 0.01001
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
 2050.332      Inf
sample estimates:
mean of x mean of y
 58744.22  51791.00

>
> #Testes de hipótese 12m
> t.test(result12m$focus,rep(50602,236),paired=FALSE,alternative =
"greater")#Com 10%

```

Welch Two Sample t-test

```

data: result12m$focus and rep(50602, 236)
t = 1.2845, df = 235, p-value = 0.1001
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
-1127.705      Inf
sample estimates:
mean of x mean of y
 54551.12  50602.00

> t.test(result12m$focus,rep(49475,236),paired=FALSE,alternative =
"greater")#Com 5%

```

Welch Two Sample t-test

data: result12m\$focus and rep(**49475**, 236)

t = 1.6511, df = 235, **p-value = 0.05002**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

-0.7054428 Inf

sample estimates:

mean of x mean of y

54551.12 49475.00

```
> t.test(result12m$focus,rep(47351,236),paired=FALSE,alternative =
"greater")#Com 1%
```

Welch Two Sample t-test

data: result12m\$focus and rep(**47351**, 236)

t = 2.342, df = 235, **p-value = 0.01001**

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

2123.295 Inf

sample estimates:

mean of x mean of y

54551.12 47351.00



idn

Bo
pro
cit
ref
Nos
são

idp

A ESCOLHA QUE
TRANSFORMA
O SEU CONHECIMENTO