



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

Júlia de Sousa Pinheiro

Padrões de heterogeneidade das expectativas de inflação mensal da Pesquisa
Focus: uma análise computacional baseada em agentes

Florianópolis
2020

Júlia de Sousa Pinheiro

Padrões de heterogeneidade das expectativas de inflação mensal da Pesquisa
Focus: uma análise computacional baseada em agentes

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. Jaylson Jair da Silveira, Dr.

Coorientador: Prof. Helberte João França Almeida, Dr.

Florianópolis
2020

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

Pinheiro, Júlia de Sousa

Padrões de heterogeneidade das expectativas de inflação
mensal da Pesquisa Focus : uma análise computacional
baseada em agentes / Júlia de Sousa Pinheiro ;
orientador, Jaylson Jair da Silveira, coorientador,
Helberte João França Almeida, 2020.

80 p.

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

Inclui referências.

1. Economia. 2. Modelo computacional baseado em
agentes. Expectativas heterogêneas. Pesquisa Focus.
Inflação.. I. Silveira, Jaylson Jair da. II. Almeida,
Helberte João França. III. Universidade Federal de Santa
Catarina. Programa de Pós-Graduação em Economia. IV. Título.

Júlia de Sousa Pinheiro

Padrões de heterogeneidade das expectativas de inflação mensal da Pesquisa

Focus: uma análise computacional baseada em agentes

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

Prof.(a) Eva Yamila Amanda da Silva Catela, Dr(a).
Instituição Universidade Federal de Santa Catarina

Prof.(a) Roberto Meurer, Dr(a).
Instituição Universidade Federal de Santa Catarina

Michel Alexandre da Silva, Dr(a).
Instituição Banco Central do Brasil

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. Jaylson Jair da Silveira, Dr.
Orientador

Florianópolis, 2020.

AGRADECIMENTOS

Agradeço a Deus, à minha família, ao meu namorado e aos meus amigos por todo o apoio durante a realização desta dissertação.

Agradeço imensamente ao meu orientador Jaylson Jair da Silveira, com quem aprendi muito, por todo o apoio, sugestões e conhecimentos transmitidos durante o desenvolvimento da pesquisa.

Agradeço ao professor Roberto Meurer e ao meu coorientador Helberte Almeida pelas sugestões feitas no decorrer da dissertação. Agradeço também à professora Eva Catela pelas sugestões feitas na qualificação do projeto e ao Michel Alexandre da Silva por ter aceito o convite para a banca de defesa da dissertação.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de mestrado concedida.

RESUMO

Propõe-se um modelo computacional baseado em agentes que represente em linhas gerais o ambiente estratégico de ganho de reputação induzido pelo ranking Top 5 da Pesquisa Focus. Mostra-se que certas propriedades agregadas das expectativas de inflação dos agentes participantes, apresentadas na literatura empírica, podem ser geradas como propriedades emergentes deste modelo computacional. Verifica-se também que as previsões da inflação se tornam mais eficazes no ambiente criado pela Pesquisa Focus, quando comparado ao caso em que não se considera o incentivo reputacional do ranking Top 5. Para tanto, foi utilizado um modelo de escolha discreta de estratégias de previsões em que os agentes possuem o incentivo de escolher a melhor estratégia de previsão pelo ganho reputacional de estar no *ranking* Top 5. Os resultados mostraram que, em geral, o modelo computacional consegue refletir os padrões de heterogeneidade dos participantes da Pesquisa Focus e que a heterogeneidade das expectativas é uma propriedade emergente do modelo. Ademais, um modelo de formação de expectativas mais geral, sem considerar o incentivo reputacional de estar no *ranking* Top 5, é elaborado de modo a mostrar que os agentes tendem a escolher a melhor estratégia de previsão com maior frequência ao se considerar o incentivo reputacional de estar no *ranking* Top 5.

Palavras-chave: Modelo computacional baseado em agentes. Expectativas heterogêneas. Pesquisa Focus. Inflação.

ABSTRACT

An agent-based computational model that represents the strategic environment of gain of reputation induced by the Top 5 ranking of Focus Research is proposed. It is shown that certain aggregate properties of the inflation expectations of the participating agents, presented in the empirical literature, can be generated as properties emerging from this computational model. It can also be seen that inflation forecasts become more effective in the environment created by the Focus Research, when compared to the case in which the reputational incentive of the Top 5 ranking is not considered. For this, a discrete choice model of forecasting strategies was used, in which agents have the incentive to choose the best forecasting strategy due to the reputational gain of being in the Top 5 ranking. The results showed that, in general, the computational model is able to reflect the heterogeneity patterns of the participants of the Focus Research and that the heterogeneity of expectations is an emerging property of the model. Furthermore, a more general expectations formation model, without considering the reputational incentive to be in the Top 5 ranking, is designed in order to show that agents tend to choose the best forecasting strategy more frequently when considering the reputational incentive of be in the Top 5 ranking.

Keywords: Agent-based computational model. heterogeneous expectations. Focus Research. Inflation.

LISTA DE FIGURAS

Figura 1 – Média das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.	40
Figura 2 – Mediana das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.	41
Figura 3 – Desvio padrão das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.	41
Figura 4 – Sensibilidade da função objetivo às variações dos parâmetros α , β e c para o modelo de formação de expectativas de curto prazo.	42
Figura 5 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo.	43
Figura 6 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor rígido.	44
Figura 7 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor adaptativo.	45
Figura 8 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor VAR.	46
Figura 9 – Variação do desvio padrão das expectativas ao aumentarmos o valor do parâmetro β	46
Figura 10 – Média das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.	55
Figura 11 – Mediana das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.	56
Figura 12 – Desvio padrão das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.	57
Figura 13 – Sensibilidade da função objetivo às variações do parâmetro β no modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.	58
Figura 14 – Proporção de respondentes e não respondentes da Pesquisa geradas pelo modelo computacional.	58
Figura 15 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões.	59

Figura 16 – Proporção de respondentes e não respondentes se todas as estratégias poderem ser adotadas sem custo/Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, quando todas as estratégias pode ser utilizadas sem custo.	60
Figura 17 – Proporção de respondentes da Pesquisa Focus e do modelo computacional.	61
Figura 18 – Variação do desvio padrão das expectativas de curto prazo ao aumentarmos o valor do parâmetro β nos modelos de formação de expectativas de curto prazo sem e com a Pesquisa Focus.	62
Figura 19 – Erros de previsão simulados quando se considera e quando não se considera o ambiente competitivo de premiação dos Top 5 e erros de previsão observados	63
Figura 20 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor rígido.	64
Figura 21 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor adaptativo.	65
Figura 22 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor VAR.	66
Figura 23 – Dispersão entre o diferencial de desempenho e o nível de dificuldade simulados	69
Figura 24 – Comparação entre diferencial de desempenho e grau de dificuldade das projeções simuladas	70
Figura 25 – Comparação entre diferencial de desempenho e grau de dificuldade das projeções observadas	70
Figura 26 – Proporção de agentes que escolhem formar previsões no modelo computacional associado à Pesquisa Focus com estrutura de custos endógena.	72
Figura 27 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, no modelo computacional associado à Pesquisa Focus com estrutura de custos endógena.	73
Figura 28 – Proporção de agentes que escolhem formar previsões no modelo computacional associado à Pesquisa Focus sem a estrutura de custo médio.	73
Figura 29 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, no modelo computacional associado à Pesquisa Focus sem a estrutura de custo médio.	74

LISTA DE QUADROS

Quadro 1 – Penalidade da instituição na data de referência de $t = N - 3$	28
Quadro 2 – Algoritmo de escolha do preditor de um agente para $t = 2, 3, \dots, 218$	38
Quadro 3 – Critério de escolha do preditor para um agente em $t = 7$	52
Quadro 4 – Critério de escolha do preditor de um agente para $t \geq 8$	52

LISTA DE TABELAS

Tabela 1 – Valores dos Parâmetros calibrados.	40
Tabela 2 – Valores dos Parâmetros calibrados no modelo de formação de expectativas de curto prazo associado à Pesquisa Focus	55
Tabela 3 – Coeficiente de correlação entre a mediana e desvio padrão das expectativas observado	65
Tabela 4 – Coeficiente de correlação entre a mediana e desvio padrão das expectativas de todos os agentes e do grupo Top 5, para o modelo computacional proposto	66
Tabela 5 – Coeficientes de correlação entre a amplitude, o valor máximo e mínimo, a mediana e o desvio padrão das expectativas observadas	67
Tabela 6 – Coeficientes de correlação entre a amplitude, o valor máximo e mínimo, a mediana e o desvio padrão das expectativas dos agentes geradas pela simulação	67
Tabela 7 – Valores de todos os parâmetros calibrados no modelo associado à Pesquisa Focus	71

SUMÁRIO

1	INTRODUÇÃO	13
2	EVIDÊNCIAS EMPÍRICAS SOBRE HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO	17
2.1	PERSISTÊNCIA DE HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO	17
2.2	EVIDÊNCIAS SOBRE A HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO CAPTADAS ENTRE OS PARTICIPANTES DA PESQUISA FOCUS	21
3	PESQUISA FOCUS E O PROCESSO DE FORMAÇÃO DE EXPECTATIVAS	25
3.1	METODOLOGIA DE CÁLCULO DO <i>RANKING</i> TOP 5 DE CURTO PRAZO	27
3.2	FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO BASEADA EM HEURÍSTICAS	29
4	FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO DE CURTO PRAZO COMO UM PROCESSO DE ESCOLHA DISCRETA	32
4.1	ESTRUTURA GERAL DE UM MODELO DE ESCOLHA DISCRETA	33
4.2	ESTRUTURA E PARAMETRIZAÇÃO DO PROCESSO DE ESCOLHA DISCRETA ASSOCIADO À FORMAÇÃO DE EXPECTATIVAS DE CURTO PRAZO	35
4.3	IMPLEMENTAÇÃO COMPUTACIONAL E CALIBRAÇÃO DO MODELO DE ESCOLHA DISCRETA ASSOCIADO À FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO DE CURTO PRAZO	37
4.4	PROPRIEDADES EMERGENTES	42
5	PESQUISA FOCUS COMO UM PROCESSO DE ESCOLHA DISCRETA	47
5.1	ESTRUTURA E IMPLEMENTAÇÃO COMPUTACIONAL DO PROCESSO DE ESCOLHA DISCRETA ASSOCIADO À PESQUISA FOCUS	48
5.2	CALIBRAÇÃO E PROPRIEDADES EMERGENTES DO MODELO DE FORMAÇÃO DE EXPECTATIVAS DE CURTO PRAZO ASSOCIADA À PESQUISA FOCUS	53
5.2.1	Formação de expectativas de curto prazo associada à Pesquisa Focus com estrutura de custos exógena	53
5.2.1.1	Calibração e testes de robustez	53
5.2.1.2	Propriedades emergentes do modelo computacional e padrões empíricos detectados pela literatura	56

5.2.2	Formação de expectativas de curto prazo associado à Pesquisa	
	Focus com estrutura de custos endógenas	70
6	CONSIDERAÇÕES FINAIS	75
	REFERÊNCIAS	78

1 INTRODUÇÃO

A formação de expectativas de inflação dos agentes em uma economia é de suma importância para a condução da política monetária. A forma como as expectativas são formadas é fundamental para entender como mudanças na taxa de juros podem vir a afetar o produto e a inflação observada. Os bancos centrais têm, portanto, um interesse crucial em monitorar as expectativas e entender o processo pelo qual elas estão sendo formadas (WEBER, 2007). Em particular, para uma economia que enfrenta um regime de metas de inflação, é necessário que a autoridade monetária adote uma atitude *forward-looking* e uma ação preventiva, tomando suas decisões baseado na previsão condicional da inflação futura (BOGDANSKI; TOMBINI; WERLANG, 2000).

Dada tal relevância das expectativas para a condução da política monetária, o Banco Central do Brasil (BCB) criou um sistema de expectativas de mercado conhecido como *Pesquisa Focus*. Todas as semanas é publicado um relatório de mercado no site da instituição com a mediana das expectativas das variáveis macroeconômicas pesquisadas, assim como a mediana das expectativas das instituições classificadas como as Top 5 de melhores acertos de previsões. O anúncio público do *ranking* Top 5 surge como uma forma de incentivo às instituições participantes da pesquisa a aprimorarem suas projeções.

Alguns trabalhos empíricos se dedicam a analisar as propriedades emergentes das expectativas a partir de dados agregados e desagregados das expectativas dos respondentes da Pesquisa Focus (e.g. Prada (2007), Carvalho e Minella (2012), Caetano e Júnior (2012), Almeida e Silveira (2017), Meurer e Lima (2017), Lemos (2017)).

Ademais, embora modelos macroeconômicos tradicionais assumam que as expectativas de inflação dos agentes são racionais e homogêneas, existem várias pesquisas que mostram evidências de existência e persistência de heterogeneidade das expectativas de inflação em dados de pesquisas de opinião de diversos países (e.g. Mankiw, Reis e Wolfers (2003), Carroll (2003), Branch (2004), Capistrán e Timmermann (2009), Pfajfar e Santoro (2010), Weber (2007), Blanchflower e MacCoille (2009)). Entre as explicações para tal heterogeneidade, destacam-se as diferenças no conjunto de informação que os indivíduos detêm e as diferenças na habilidade cognitiva de captar e processar essas informações. É com essa motivação que a presente dissertação procura, utilizando uma abordagem computacional baseada em agentes, contribuir com a literatura de expectativas inflacionárias heterogêneas por meio da elaboração um modelo de escolha discreta, no ambiente competitivo de ganho de reputação inspirado no *ranking* Top 5, e considerando que o custo de formação das expectativas é heterogêneo entre os agentes, de forma que a heterogeneidade das previsões tenha

como pano de fundo um ambiente com heterogeneidade das habilidades cognitivas.

O modelo proposto neste projeto toma como referência o modelo desenvolvido por Almeida e Silveira (2017). Como forma de analisar o processo de formação de expectativas de inflação no Brasil, esses autores fizeram uso de uma abordagem denominada *Adaptively Rational Equilibrium Dynamics (ARED)*, que foi introduzida por Brock e Hommes (1997). No *ARED*, os agentes adaptam as suas previsões ao longo do tempo escolhendo uma heurística de previsão no conjunto finito de preditores disponíveis a ele, com base em suas performances passadas. Em Almeida e Silveira (2017), os agentes formam suas escolhas de forma racionalmente heterogênea no sentido em que eles escolhem suas estratégias de previsão da inflação que se mostram individualmente ótimas em um dado momento, dados os graus de acurácia passada das mesmas. Os referidos autores utilizaram heurísticas de previsão de forma que, a cada período da simulação, os agentes podiam escolher uma dentre as três heurísticas de previsão disponíveis a eles. Os três métodos de previsões, por sua vez, foram inspirados nas heurísticas de previsão utilizadas por Branch (2004), sejam elas, um preditor rígido, um preditor adaptativo e um vetor autoregressivo (VAR).

No contexto elaborado pela presente pesquisa, os agentes se deparam com um sistema de premiação inspirado no *ranking* Top 5 do Banco Central do Brasil, de modo que a sua posição no *ranking* influencia sua tomada de decisões por ser um incentivo reputacional para o agente (instituição). Assim, de forma a reproduzir o ambiente criado pela Pesquisa Focus, cada instituição pode escolher, a cada período de tempo, fornecer ou não suas expectativas a respeito da inflação. Para as instituições que escolhem formar suas expectativas no período, elas podem o fazer por meio de quatro diferentes heurísticas de previsão. As três primeiras heurísticas são as mesmas utilizadas por Almeida e Silveira (2017), que por sua vez, como já dito, inspiraram-se em Branch (2004). Adiciona-se ainda uma quarta heurística de previsão que consiste em imitar a mediana das previsões, para o período corrente, das instituições que estão no *ranking* Top 5. Tais instituições (agentes) são classificadas como Top 5 por possuírem, em média, os menores erros de previsão nos últimos 6 períodos.

Inspirado pela abordagem *ARED*, cada instituição escolherá a sua estratégia com base na performance passada da mesma. Além disso, assim como em Almeida e Silveira (2017), assume-se que as instituições possuem um custo ao formar suas previsões, custo este baseado no *custo médio do preditor* (igual para todos os agentes) e um componente estocástico referente a dispersão das habilidades cognitivas, de modo a se formar um ambiente onde os agentes possuem racionalidade limitada. Como afirma Conlisk (1996), o indivíduo com racionalidade limitada pode não modificar o comportamento que leva ao erro sistemático por causa do custo de deliberação, isso porque uma determinada heurística de previsão pode prover uma solução barata, enquanto soluções mais elaboradas podem ser excessivamente caras.

Com isso, procura-se criar um laboratório computacional que represente o ambiente estratégico de ganho de reputação movido pelo *ranking* Top 5 da Pesquisa Focus, de forma a mostrar que as propriedades agregadas apresentadas na literatura podem ser geradas como propriedades emergentes de um modelo computacional baseado em agentes heterogêneos com racionalidade limitada. Ademais, um modelo de formação de expectativas heterogêneas mais geral, sem considerar o ambiente competitivo de incentivo à melhora das previsões, criado pela Pesquisa Focus, também é elaborado na presente dissertação de forma a mostrar diferenças pontuais que surgem ao se considerar o incentivo à melhora das previsões. Em particular, procura-se verificar se a escolha das estratégias de previsão se torna mais eficaz no ambiente criado pela Pesquisa Focus, em relação ao caso em que não se considera o incentivo reputacional do *ranking* Top 5.

Portanto, apontam-se os seguintes objetivos da presente dissertação: mostrar que um modelo computacional baseado em agentes heterogêneos com racionalidade limitada consegue refletir padrões de heterogeneidade dos participantes da Pesquisa Focus, em um ambiente estratégico de ganho de reputação motivado pelo *ranking* Top 5; abordar boa parte da literatura que mostra evidências empíricas a respeito da persistência de heterogeneidade das expectativas de inflação de uma forma geral; expor trabalhos empíricos que analisaram padrões de heterogeneidades das expectativas de inflação brasileira por meio do banco de dados disponível pelo Banco Central do Brasil, de modo a dar suporte para o desenvolvimento do modelo e a análise das propriedades emergentes; e, por fim, verificar diferenças pontuais que surgem ao se comparar os processos de escolha de estratégias de previsão no ambiente com e sem o incentivo reputacional criado pelo *ranking* Top 5 da Pesquisa Focus.

A presente dissertação foi estruturada como segue. No próximo capítulo, é feita uma revisão bibliográfica de trabalhos empíricos sobre existência de heterogeneidade nas expectativas de inflação e de trabalhos empíricos que se destinaram a analisar padrões de heterogeneidade das expectativas de inflação das instituições cadastradas na Pesquisa Focus. No capítulo 3 é feita uma descrição mais detalhada sobre a Pesquisa Focus, assim como também é descrito a metodologia de apuração das instituições que compõem o *ranking* Top 5 de melhores acertos de previsão, e é feito um levantamento a respeito do processo de formação de expectativas utilizado para estudar os padrões de heterogeneidade dos participantes da pesquisa. O capítulo 4 é destinado à apresentação da estrutura geral de um modelo de escolha discreta, assim como a apresentação de um modelo computacional de formação de expectativas de inflação de curto prazo sem considerar o ambiente competitivo de seleção do *ranking* Top 5, de modo que este possa ser posteriormente comparado ao modelo que considera o ambiente competitivo. No capítulo 5, a estrutura geral do modelo de escolha discreta, descrita no capítulo 4, é utilizada de modo a se desenvolver um modelo computacional

de formação de expectativas de curto prazo associado à Pesquisa Focus, a fim de avaliar os padrões de heterogeneidade no ambiente competitivo criado pela pesquisa.

2 EVIDÊNCIAS EMPÍRICAS SOBRE HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO

As expectativas daqueles diretamente envolvidos em formar preços e salários têm um importante impacto no nível de inflação. Com efeito, os trabalhadores buscarão salários nominais mais altos se tiverem expectativa de inflação alta para o futuro. Isso poderá levar a pressões nos preços dos produtos das empresas. Ademais, se os empresários esperam que a inflação seja maior no futuro, eles podem se tornar mais inclinados a aumentar os preços, acreditando que podem fazer isso sem sofrer uma queda na demanda dos seus produtos. Para as famílias, se a expectativa for de inflação elevada, para um dado caminho para a taxa de juros nominais, isso implica uma menor taxa de juros reais esperada, fazendo o consumo ser mais atrativo do que a poupança (BLANCHFLOWER; MACCOILLE, 2009).

Dada a referida importância das expectativas para o nível da inflação e, por consequência, para a condução da política monetária, diversos são os trabalhos que se destinaram a mostrar características a respeito da formação de expectativas. Apesar do destaque das expectativas racionais e homogêneas em modelos macroeconômicos, estudos empíricos com dados de pesquisa de opinião mostram limitações dessas hipóteses. É com essa motivação que, neste capítulo introdutório, procura-se apresentar evidências empíricas de existência e persistência de heterogeneidade das expectativas de inflação. Em particular, a seção 2.1 busca englobar boa parte da literatura que, por meio de diferentes dados de pesquisas de opinião (desde consumidores em geral até profissionais de previsão) realizadas em diversos países, mostra evidências robustas sobre a existência de heterogeneidade nas expectativas de inflação em tais países, assim como possíveis explicações para a heterogeneidade das expectativas. Alguns experimentos controlados em laboratório sobre formação de expectativas de inflação também são abordados na referida seção.

Já a seção 2.2 possui como foco a revisão de trabalhos que utilizaram dados de opinião da Pesquisa Focus a respeito das expectativas de inflação do Brasil. Essa última seção visa englobar os principais trabalhos que mostraram, além de evidências empíricas de existência de heterogeneidade das expectativas de inflação da Pesquisa Focus, também diversos padrões heterogeneidade que essas expectativas apresentam. Tais padrões servirão como motivação para a análise de algumas propriedades emergentes do modelo computacional de formação de expectativas de inflação associado à Pesquisa Focus, elaborado na presente dissertação.

2.1 PERSISTÊNCIA DE HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO

A literatura empírica sobre formação de expectativa de inflação se concentra entre evidências geradas por meio de pesquisa de opinião e evidências obtidas através

de experimentos controlados em laboratório. Dentre os estudos que utilizam pesquisa de opinião, Mankiw, Reis e Wolfers (2003) encontraram fortes evidências a cerca da heterogeneidade das expectativas para a inflação por meio de estatísticas descritivas de dados da *Michigan Survey of Consumer Attitudes and Behavior*, da *Livingston Survey* e da *Survey of Professional Forecasts*. Esses dados, referentes à economia norte-americana, contêm expectativas de consumidores em geral, economistas e especialistas em previsões, respectivamente. No estudo, os autores encontraram evidências de divergências a respeito das expectativas de inflação e que estas divergências variam ao longo do tempo. Em especial, quando a inflação varia muito, a dispersão das expectativas tende a aumentar. Os autores também encontraram indícios de rejeição da hipótese de racionalidade. Ao regredir os erros de previsão contemporâneos com os erros de previsão passados, eles encontraram evidências de autocorrelação, ou seja, para a amostra considerada, as informações dos erros passados não estão sendo completamente explorados para gerar as previsões. Os autores consideram como possíveis causas de heterogeneidade das expectativas a rigidez informacional e as diferentes habilidades de processar as informações.

Uma pesquisa semelhante é feita por Carroll (2003), porém utilizando dados apenas da *Michigan Survey* e da *Survey of Professional Forecasts*. O autor encontrou evidências de que a expectativa de inflação é heterogênea para os dois conjuntos de respondentes considerados. Além disso, as expectativas por parte dos profissionais mostraram maior acurácia em relação à previsão da população em geral. Foi encontrado ainda uma relação de causalidade de Granger estatisticamente significativa, indo no sentido das previsões de profissionais para a previsão da população em geral.

Branch (2004) procurou evidências empíricas de que, com a presença do custo de informação, pode ser racional para os agentes selecionar métodos de previsão que não sejam o de expectativas racionais. Isso porque os agentes atualizam suas previsões pesando não só o benefício (acurácia) provido por cada preditor, mas também os custos de utilizá-los. O autor, utilizando dados da *Michigan Survey* para a expectativas de inflação 12 meses à frente, fez uma análise da dinâmica de seleção do preditor por meio de um modelo de escolha discreta no qual os agentes formam suas previsões para a inflação, a cada período considerado, escolhendo como mecanismo de previsão o preditor rígido, o preditor adaptativo ou um vetor autoregressivo (VAR). Cada preditor, por sua vez, possui um custo para ser utilizado, que foi estimado econometricamente. Ademais, a proporção de agentes que utilizam cada preditor é uma função do seu erro quadrático médio. Os resultados encontrados pelo autor sugerem que os agentes são racionalmente heterogêneos no sentido de que a escolha de cada preditor é a escolha ótima para si. Assim, algumas vezes não vale a pena investir esforço em um diferente método de previsão se o benefício que esse método prover (maior acurácia) for inferior ao custo de utilizá-lo. Além disso, a proporção de agentes que escolhem cada preditor

tende a variar inversamente com o erro de previsão ao longo do tempo, e os agentes tendem a utilizar o preditor VAR com maior frequência do que o preditor adaptativo e o preditor rígido.

Posteriormente, Capistrán e Timmermann (2009) mostraram que as dispersões das expectativas de inflação variam ao longo do tempo, de forma a refletir o nível e a variância da inflação observada. Como forma de explicar esse fenômeno, os autores propuseram: (1) o mecanismo de perdas assimétricas, que captura a ideia de que prever a inflação acima ou abaixo do valor observado pode ser diferente entre os agentes; (2) a heterogeneidade da função perda, que indica que períodos com alto nível de incerteza macroeconômica coincide com períodos em que a dispersão e viés nas crenças deve ser maior; e (3) um componente de viés constante, que captura a tendência dos agentes de superprever a inflação. Utilizando dados da *Survey of Professional Forecasters* e uma função perda assimétrica, os autores mostraram evidências de que os erros de previsão estão positivamente correlacionados, ao realizar o teste de *Ljung-Box*. Ademais, foi verificado que o histograma dos erros de previsão média individual está inclinado para a direita, indicando um viés de alta para as previsões, e que o erro médio de previsão depende da variância condicional da inflação. Por fim, foi encontrado ainda uma relação positiva entre a variância condicional da inflação e a dispersão das expectativas.

Ainda utilizando dados de pesquisa de opinião dos Estados Unidos, Pfajfar e Santoro (2010), com o objetivo de explicar a evolução das previsões para a inflação ao longo do tempo, exploraram os percentis da distribuição dos dados da *Michigan Survey*, para as expectativas de inflação 12 meses à frente. Eles concluíram que as projeções para a inflação são heterogêneas em todos os períodos analisados, e que a hipótese nula de racionalidade não pode ser rejeitada para poucos percentis, geralmente localizados em torno ou ligeiramente acima da previsão mediana. Além disso, os percentis abaixo da expectativa mediana foram caracterizados por projeções de agentes que não exploraram toda a informação relevante disponível ao prever a inflação, se mostrando previsões altamente inerciais as quais, de tempos em tempos, os coeficientes são atualizados com relação ao último erro observado. As previsões do lado direito da expectativa mediana puderam ser associados ao aprendizado adaptativo, com menor frequência de atualização durante períodos de inflação estável.

Já Weber (2007) focou nos dados de opinião da Europa. O autor, utilizando dados das expectativas de famílias e de profissionais de previsão para as economias da Alemanha, França, Itália, Espanha e Holanda, encontrou evidências de heterogeneidade das expectativas e que, em geral, elas resultam de um processo de aprendizado. Ademais, os resultados indicaram que os profissionais de previsão atualizam seus conjuntos de informações com maior frequência e conseguem captar mudanças estruturais mais rapidamente do que as famílias. A pesquisa feita pelo autor também mostrou evi-

dências de que, em países com inflação mais elevadas, os agentes atualizam seus conjuntos de informação com maior frequência.

Outra forte evidência de heterogeneidade na formação de expectativas foi encontrada por Blanchflower e MacCoille (2009). Os autores analisaram três pesquisas de opinião da população do Reino Unido a respeito da expectativa de inflação e observaram que existem altas taxas de não respondentes nas pesquisas e que, em geral, as expectativas são *backward-looking*. Foram encontradas ainda diferenças na formação de expectativas de inflação de acordo com características como idade, escolaridade, renda e emprego. Em particular, a percepção a respeito da inflação atual e passada pareceu influenciar menos a formação de expectativas dos respondentes com maior nível de educação do que aqueles com menor nível de educação. Ademais, os autores concluíram que, em períodos em que a inflação se encontrava acima da meta e mais volátil, as expectativas foram menos influenciadas pela inflação corrente.

Dentre os estudos que buscam evidências acerca da heterogeneidade de expectativa de inflação por meio de experimentos controlados em laboratório, destacam-se os trabalhos de Adam (2007), Pfajfar e Žakelj (2018), Assenza *et al.* (2013) e Burke e Manz (2014). Adam (2007) realiza um estudo em laboratório de uma economia com preços rígidos e choques de demanda nominais para avaliar se desvios das expectativas em relação às expectativas racionais é um fator que contribui para a persistência do desvio da inflação e do nível de produto dos seus respectivos níveis de estado estacionário. Para testar se os desvios são persistentes em uma economia que possui rigidez nos preços e choques de demanda nominal, estudantes da *University of Salerno*, na Itália, e da *Goethe University of Frankfurt*, na Alemanha, responderam suas previsões para a inflação futura. Eles tiveram o incentivo de prover a melhor previsão possível pois receberam um pagamento que dependia negativamente dos seus erros de previsão. As expectativas foram então substituídas na equação de equilíbrio temporário do modelo e determinaram um resultado para o novo nível de inflação e produto que foi anunciado aos participantes. Ao repetir o processo 420 vezes, o autor conclui que a inflação e o produto mostram desvios regulares e persistentes do nível de estado estacionário. Esse comportamento emergiu pois os estudantes não utilizaram o preditor de expectativas racionais. De fato, eles utilizam o preditor que minimiza o erro quadrático médio, mas condicionado a apenas uma variável explicativa.

Por outro lado, o estudo realizado em laboratório por Pfajfar e Žakelj (2018) tem como resultado que 40% dos participantes se comportam de forma racional e eles tendem a trocar de previsor com o tempo, de forma que evidências de heterogeneidade nas previsões entre os estudantes que participaram da pesquisa foram encontradas.

Assenza *et al.* (2013) estudaram o processo de formação de expectativas de inflação em laboratório em um ambiente onde flutuações das variáveis agregadas dependem endogenamente das previsões individuais para a inflação e para o hiato

do produto. 120 alunos da Universidade de Amsterdã realizaram previsões para 50 períodos. Os autores encontraram evidências de heterogeneidade das expectativas e concluíram que os indivíduos tendem a basear suas previsões em métodos simples.

Por fim, Burke e Manz (2014) realizaram uma pesquisa a respeito da relação entre o grau de instrução econômica e a acurácia das expectativas de inflação. Os autores investigaram dois canais através dos quais o conhecimento econômico pode contribuir para melhores previsões de inflação, a saber, a coleta de informação e o devido uso destas. No experimento, as pessoas respondem suas projeções para a inflação (seja em uma economia simulada ou para a economia dos EUA) e recebem incentivos para realizar uma previsão mais acurada. As descobertas dos autores sugeriram que uma porção significativa da heterogeneidade demográfica nas expectativas de inflação, observadas nos dados de pesquisa de opinião, pode ser resultante da heterogeneidade no grau de conhecimento de economia.

Nesta seção, foram apresentadas evidências empíricas de heterogeneidade na formação de expectativa de inflação em trabalhos desenvolvidos fora do Brasil. Na próxima seção, serão apresentados alguns trabalhos que utilizaram dados de expectativas para a inflação brasileira, tanto agregados quanto desagregados, fornecidos pelo Banco Central do Brasil (BCB), com o objetivo de analisar a heterogeneidade de previsões das instituições respondentes da Pesquisa Focus.

2.2 EVIDÊNCIAS SOBRE A HETEROGENEIDADE DAS EXPECTATIVAS DE INFLAÇÃO CAPTADAS ENTRE OS PARTICIPANTES DA PESQUISA FOCUS

Os trabalhos revisados a seguir fazem uma análise em torno das séries temporais obtidas por meio da Pesquisa Focus e divulgados no site do BCB. Segundo a instituição, atualmente estão habilitados cerca de 140 respondentes que fornecem projeções para diversas variáveis macroeconômicas, sendo o foco do presente trabalho a revisão de estudos que analisam as expectativas para o Índice de Preço ao Consumidor Amplo (IPCA). O BCB fornece, ainda, o *ranking* Top 5 de curto, médio e longo prazos de melhores acertos de previsões, de forma a incentivar o aprimoramento das previsões dos participantes da pesquisa e reconhecer o esforço analítico.

Utilizando a teoria dos torneios, Prada (2007) analisou a estrutura de premiação do *ranking* Top 5 do BCB como um mecanismo de incentivo para obter projeções atualizadas do mercado e estimular as instituições a aprimorarem suas projeções. Conforme relata a autora, apesar de não existir exatamente uma premiação financeira para as instituições que compõem o *ranking*, a divulgação dos vencedores tem um valor de propaganda, ao contribuir para a formação de reputação dos mesmos. Ela também chama a atenção para o fato de que o BCB possivelmente estivesse com o problema de ação oculta antes da implementação do *ranking* Top 5, em que o Banco Central é o principal e as instituições pesquisadas são os agentes. A autora argumenta

que “[...] uma das vantagens do *ranking* Top 5 para contornar esse problema é o fato de ser menos custoso e ser mais viável observar o desempenho relativo do que medir o esforço individual sobre o resultado de cada agentes individualmente.” (PRADA, 2007, p. 9).

Prada (2007) analisa ainda a heterogeneidade das instituições participantes da Pesquisa Focus por meio da comparação entre desempenho das instituições Top 5 e o desempenho geral das instituições participantes, baseado nos erros calculados a partir da mediana das projeções de cada grupo. Uma verificação do diferencial de desempenho entre as instituições também foi feita ao se encontrar uma relação positiva entre o diferencial de desempenho e o desvio padrão.

Carvalho e Minella (2012), utilizando dados desagregados das expectativas de inflação da Pesquisa Focus, encontraram indícios de que as previsões das instituições que compõem o *ranking* Top 5 influenciam outras previsões, por meio da regressão da expectativa de todas as instituições em relação à expectativa das instituições que compõem o *ranking* Top 5. Na análise feita pelos autores, a dispersão das expectativas de inflação, taxa de câmbio e taxa de juros se mostraram altamente correlacionadas, indicando que períodos de aumento do prêmio de risco do país tende a ser caracterizado por aumento na dispersão das previsões. Com relação a performance das expectativas das instituições que participam da pesquisa, os autores concluíram que, para toda a amostra considerada (janeiro de 2002 a junho de 2007), o erro quadrático médio das previsões das instituições se aproximam dos erros quadráticos médio dos modelos ARMA, VAR e BVAR estimados. Os autores encontraram ainda que o sistema de metas de inflação desempenha um papel importante nas expectativas de inflação e que a inflação passada, a taxa de câmbio e os preços das commodities (ao nível de 10% de significância) também são variáveis com poder explicativo para as expectativas dos agentes. Carvalho, Minella *et al.* (2009) verificaram também a racionalidade das expectativas da Pesquisa Focus, chegando a conclusão de que as expectativas para a inflação são não viesadas, mas não podem ser consideradas totalmente eficientes.

Também baseado em dados desagregados das expectativas de inflação da Pesquisa Focus, Caetano e Júnior (2012) utilizaram o teste *Superior Predictive Ability* (SPA), em períodos de curto e longo prazo, para verificar a capacidade preditiva superior de instituições que compõem o conjunto de respondentes da pesquisa. Eles encontraram que as instituições apresentam divergências em relação à projeção feita, sendo que algumas instituições apresentam habilidade preditiva superior. Além disso, eles concluíram que a dinâmica de expectativas das instituições, no geral, apresentam algum grau de inércia, indicando que o ajustamento ocorre gradualmente após um choque.

Almeida e Silveira (2017), por meio de uma abordagem computacional baseada em agentes, propuseram um modelo no qual o processo de seleção baseado em heu-

rísticas é regido por um atributo privado (acurácia menos o custo médio do preditor), e um atributo não observável relacionado à dispersão das habilidades cognitivas (habilidades cognitivas heterogêneas). Os autores avaliaram também o caso em que existem interações sociais e encontram que, em ambos os casos, existe heterogeneidade na distribuição dos preditores, mas o processo de seleção de heurísticas torna-se mais eficaz no caso em que há interação social entre os agentes. Os referidos autores descreveram a função utilidade dos agentes como negativo da soma do desvio das expectativas em relação ao valor observado (acurácia do preditor) e o custo de utilizar esse preditor.

Meurer e Lima (2017) analisaram a heterogeneidade das expectativas de inflação por meio de estatísticas descritivas e estimações econométricas para o comportamento da mediana, amplitude, dispersão e recorrência de instituições nos Top 5 de maior acerto das previsões. Os autores utilizaram dados agregados fornecidos pelo BCB, no período de janeiro de 2003 a agosto de 2016, de previsões referentes ao curto prazo. A análise mostrou que a mediana das expectativas do grupo Top 5 tem correlação muito forte com a mediana do conjunto dos respondentes, que existe um ajuste gradual da mediana das expectativas e uma relação positiva da variação da mediana com a dispersão das expectativas, para o período estudado, e que boa parte das instituições participantes da pesquisa ajustam suas expectativas no dia ou no dia anterior à data de referência para apuração do grupo top 5, o que foi evidenciado pela significância estatística das alterações de mediana das expectativas nesses dias.

Em suas considerações finais, Meurer e Lima (2017) apontam que o fato de a data de referência para apuração do *ranking* Top 5 ser importante para as instituições geraria uma discussão teórica sobre o desempenho das previsões. Segundo eles, se o sistema de premiação considerasse um número maior de dias, isso possivelmente levaria a previsões potencialmente melhores. No entanto, os autores chamam atenção para o fato de que o aumento dos dias considerados para apuração do *ranking* Top 5 envolveria um custo gerado pela necessidade constante de revisão das previsões por parte dos respondentes.

Por fim, Lemos (2017), utilizando dados agregados da Pesquisa Focus da expectativa de inflação acumulada para os próximos 12 meses, indicou que as discordâncias nas expectativas de inflação no Brasil aumentam junto com aumentos da inflação observada, aumentam também quando há uma mudança acentuada na inflação observada, embora não demonstrem relação clara com o hiato do produto. O autor analisa ainda se as expectativas de inflação observada se conformam às características associadas à hipótese de expectativas racionais, testando, por exemplo, se as expectativas tendem à um valor central potencialmente enviesado e se há relação entre os erros de previsão atuais e os erros anteriores. O teste indicou que aproximadamente 30% do erro anterior persiste na mediana das expectativas atuais. Lemos (2017) também

testou a extensão em que as expectativas de inflação levam em consideração as informações públicas, regredindo o erro de previsão em função de uma série de variáveis macroeconômicas publicadas no período anterior à coleta. Os resultados sugeriram uma reação exagerada dos agentes à inflação realizada e ao nível de desemprego.

No próximo capítulo, a Pesquisa Focus será analisada com mais detalhes, assim como a metodologia de cálculo do *ranking* Top 5 de curto prazo de melhores projeções para a inflação. Ademais, as possibilidades de ação para os participantes da pesquisa, descritas no decorrer do próximo capítulo, leva a crer na necessidade de se estudar o processo de formação de expectativa dos participantes, de modo que a última seção deste capítulo será destinada a propor mecanismos de previsão que serão utilizados no modelo computacional desenvolvido no capítulo 4.

3 PESQUISA FOCUS E O PROCESSO DE FORMAÇÃO DE EXPECTATIVAS

Segundo o BCB, a pesquisa de expectativas de mercado foi iniciada alguns meses antes da implementação formal do regime de metas de inflação, período em que estavam sendo desenvolvidos estudos e modelos econométricos para a projeção da inflação e de outras variáveis macroeconômicas, com o objetivo de fornecer o instrumental técnico necessário para a efetivação do regime em junho de 1999. Naquele mesmo ano e no ano que se seguiu, as instituições cadastradas forneciam suas expectativas apenas para os índices de preço IGP-DI, IGP-M e IPA, assim como projeções para o crescimento do PIB (BANCO CENTRAL DO BRASIL, 2019c). As informações eram disponibilizadas por telefone, correio eletrônico ou fax. Com a crescente importância do monitoramento das expectativas e a sofisticação do sistema, foi criado pelo BCB em 2001 a página na internet do *Sistema de Expectativas de Mercado*.

A pesquisa de expectativa é conhecida como Pesquisa Focus. Como relatado por Marques, Fachada e Cavalcanti (2003), a partir de dados coletados, é calculado em tempo real as estatísticas da amostra, gerando relatórios diários para os membros do Comitê de Política Monetária (Copom). Ademais, é publicado semanalmente o Relatório de Mercado no *site* do BCB com a mediana das expectativas coletadas nos 30 últimos dias corridos até a data de referência do relatório. Na primeira segunda-feira de cada mês, é gerado também um relatório com a evolução das distribuições de frequência das medianas das projeções do IPCA do ano corrente e dos próximos 3 anos, e do crescimento do PIB, da taxa Selic e da taxa de câmbio para o ano corrente e para o ano que se segue (BANCO CENTRAL DO BRASIL, 2019c).

Atualmente, a Pesquisa Focus coleta diariamente projeções de um conjunto de aproximadamente 140 instituições, entre elas bancos, gestores de recursos e consultorias. Segundo o BCB, para uma instituição ser incluída na pesquisa é exigido que se tenha uma equipe especializada em projeções macroeconômicas e regularidade nas projeções fornecidas. As instituições cadastradas fornecem expectativas para índices de preço (IPCA-15, IPCA, IGP-DI, IGP-M, IPA-M, IPA-DI, INPC e IPC-Fipe), para a atividade econômica (PIB, PIB industrial, PIB agropecuário, PIB serviços e produção industrial), para a taxa de câmbio, para a meta da taxa Selic, para o setor externo (importação, exportação e balança comercial) e para variáveis relacionadas ao setor fiscal (resultado primário, resultado nominal e dívida líquida do setor público). São divulgadas séries históricas da média, da mediana, do desvio-padrão, do coeficiente de variação, do valor máximo e do valor mínimo das expectativas dos participantes da pesquisa para um determinado mês, assim como o número de instituições que forneceram suas expectativas.¹

¹ Disponível em <https://www3.bcb.gov.br/sgspub/localizarseries/localizarSeries.do?method=prepararTelaLocalizarSeries>.

Segundo o Relatório de Inflação de dezembro de 2004,² as pesquisas de expectativas feitas pelos bancos centrais geralmente consistem na sondagem das expectativas de especialistas, usualmente do setor privado, na sondagem das expectativas das população em geral e no acompanhamento indireto das expectativas com base em preços dos ativos financeiros. Conforme esse documento, a pesquisa de expectativas com base em preços de ativos financeiros tem a vantagem de que os agentes privados devem formar suas melhores expectativas ao transacionarem os ativos a esses preços, porém existe a desvantagem de que a diferença de retorno entre ativos nominais e indexados reflete, além a expectativa de inflação, um componente de prêmio de risco. Em especial, em mercados de ativos nominais ou indexados com alta volatilidade e baixa liquidez, que tornam maiores e mais instáveis o prêmio de risco, o esforço imediato deve se voltar para a melhoria da acuidade das informações reportadas em sondagens (BANCO CENTRAL DO BRASIL, 2004). Com isso, a Pesquisa Focus procura incentivar o aprimoramento da capacidade preditiva das instituições participantes da pesquisa, por meio da elaboração de um *ranking* Top 5 de instituições com melhores acertos das projeções.

Os *rankings* Top 5 de curto, médio e longo prazo são calculados desde julho de 2001.³ As instituições são anunciadas mensalmente no site do BCB, e a mediana das expectativas feitas por essas instituições são divulgadas semanalmente no Relatório de Mercado do Focus. As instituições são avaliadas pela precisão de suas projeções para o IPCA, o IGP-M, o IGP-DI, a taxa de câmbio e a meta para a taxa Selic, formando-se um *ranking* das 5 instituições com maior nível de acerto com relação às expectativas para cada uma dessas variáveis.

A partir de janeiro de 2009 começou a ser divulgado também o *ranking* anual com base nos erros utilizados para o cálculo do *ranking* de curto e médio prazos referente aos meses de janeiro a dezembro do ano anterior ao anúncio. A classificação anual procura reconhecer o esforço analítico das instituições que têm sido mais constantes no acerto das previsões, de forma a incentivar ainda mais o investimento nas atividades de pesquisa macroeconômica (BANCO CENTRAL DO BRASIL, 2019b). O sistema de expectativas do permite que cada participante da pesquisa possa visualizar sua classificação no *ranking* Top 5 desde janeiro de 2002 (MARQUES et. al., 2003).

Na seção a seguir é apresentado a metodologia de seleção das instituições que compõem o *ranking* Top 5, seguindo a metodologia explicitada pela Pesquisa Focus do BCB para cálculo do *ranking* Top 5 mensal de curto prazo, foco deste projeto.⁴

² Disponível em <https://www.bcb.gov.br/htms/relinf/port/2004/12/ri200412b7p.pdf>

³ São avaliadas as projeções com defasagem de 1, 4 e 12 meses para os *rankings* de curto, médio e longo prazos, respectivamente.

⁴ Para mais informações, ver "Instituições Top 5 - Classificação Anual para as categorias Curto e Médio Prazo e Consolidação da Metodologia", disponível em <https://www.bcb.gov.br/conteudo/depec/NotasTecnicas/2003nt36SistemaBacenExpectMercadop.pdf>.

3.1 METODOLOGIA DE CÁLCULO DO *RANKING* TOP 5 DE CURTO PRAZO

Toda discussão a respeito da metodologia de cálculo do *ranking* Top 5, feita nesta seção, foi retirado da metodologia publicada do site do BCB.⁵ O cálculo dos *rankings* de curto prazo é baseado em equações que determinam penalidades para cada instituição, e tais penalidades são calculadas com base em previsões feitas até a data de referência para o respectivo mês. Entende-se por data de referência de um determinado mês, o dia em que é verificado o nível de acerto da previsão mais atualizada das instituições feitas no intervalo de um mês até a data de referência. Até dezembro de 2018, a data de referência para o IPCA, foco do presente trabalho, era o último dia útil anterior à data da divulgação do IPCA-15. A partir de janeiro de 2019, a data de referência para o IPCA passou a ser a sexta-feira imediatamente anterior à reunião do Comitê de Política Monetária (Copom), caso haja a reunião no mês, ou penúltima sexta-feira do mês para os meses que não contenham sexta-feira imediatamente anterior à reunião do Copom (BANCO CENTRAL DO BRASIL, 2019a).

Para a definição do *ranking* Top 5, as instituições são avaliadas pela precisão de suas projeções com defasagem de um mês em relação à publicação do indicador, nos últimos 6 meses, com base na seguinte fórmula de penalidade:

$$\psi^R = \sum_{t=N-5}^N \{(\text{penal.média})_{d_t} \cdot (1 - j_{d_t}) + j_{d_t} \cdot [(\text{penal.máxima})_{d_t} \cdot (1 - k_{d_t}) + |E_{d_t} \tau_t^R - \tau_t| \cdot k_{d_t}]\} / 6, \quad (3.1)$$

na qual:

ψ^R é a penalidade atribuída à instituição R ;

t é o mês para o qual o desvio é calculado;

N é o mês referente à última data de referência do período calculado;

d_t é a data de referência do indicador τ no mês t ;

τ_t é o resultado ocorrido da variável pesquisada τ no mês t ;

$E_{d_t} \tau_t^R$ é a projeção da instituição R que seja válida em d_t para τ_t ;

$(\text{penal.média})_{d_t}$ é o desvio absoluto médio das projeções válidas em d_t , para τ_t , em relação ao resultado ocorrido no mês t ;

$(\text{penal.máxima})_{d_t}$ é o desvio absoluto máximo das projeções válidas em d_t , para τ_t , em relação ao resultado ocorrido no mês t ;

$k_{d_t} = 0$ se a instituição não tem projeção válida na data de referência (d_t);

$k_{d_t} = 1$ se a instituição tem projeção válida na data de referência d_t ;

$j_{d_t} = 0$ se a data de referência é anterior ao dia da primeira previsão da instituição para o indicador τ ;

⁵ Disponível em https://www.bcb.gov.br/content/controleinflacao/Documents/Expectativas_mercado/Focus/E20080211-Top5-Classificacao-Anual-para-as-Categorias-Curto-e-Medio-Prazo-e-Cons.pdf.

$j_{d_t} = 1$ se a data de referência d_t é igual ou superior ao dia da primeira previsão da instituição para o indicador τ .

Considerando-se (3.1), nota-se que as penalidades se baseiam nos desvios das projeções da instituição i caso a instituição possua previsões atualizadas até a data de referência para cálculo. Se a instituição não estiver atualizado suas previsões em um determinado mês t , a penalidade daquele mês será o desvio absoluto máximo das previsões, se a instituição i já estiver fornecido alguma previsão para a pesquisa, ou o desvio absoluto médio das previsões, caso contrário. Como exemplo, é mostrado no Quadro 1 a penalidade de uma instituição no mês $t = N-3$, que deve ser utilizada para calcular o *ranking* Top 5 do mês N .

Quadro 1 – Penalidade da instituição na data de referência de $t = N-3$

Situação da instituição na data de referência de $t = N-3$	Valor de k_{d_3}	Valor de j_{d_3}	Penalidade
Caso 1: instituição possui previsão	$k_{d_{N-3}} = 1$	$j_{d_{N-3}} = 1$	$ E_{d_{N-3}} \tau_{N-3}^R - \tau_{N-3} $
Caso 2: instituição não possui previsão e contribuiu em $t = N-4$ e/ou $t = N-5$	$k_{d_{N-3}} = 0$	$j_{d_{N-3}} = 1$	penal.máxima
Caso 3: instituição não possui previsão e não contribuiu em $t = N-4$ e $t = N-5$	$k_{d_{N-3}} = 0$	$j_{d_{N-3}} = 0$	penal.média

Fonte: Elaboração própria.

As instituições no mês $t=N$ são, então, classificadas pelo valor do seu respectivo ψ^R para o mês N , que será a média das penalidades recebidas nos seis últimos meses, no caso do *ranking* Top 5 de curto prazo. A ordem de classificação se dá do menor valor de ψ^R para o maior valor de ψ^R .

Por meio da metodologia de cálculo do *ranking* Top 5 de curto prazo, apresentada nesta seção, observa-se que as instituições cadastradas na Pesquisa Focus se deparam com duas possibilidades de ação: fornecer ou não fornecer suas expectativas. Um respondente da Pesquisa Focus deve, naturalmente, formar expectativas sobre as inflações futuras. Conseqüentemente, faz-se necessário tratar do processo de formação de expectativas das instituições que fornecem à pesquisa suas projeções para a inflação, de modo a conseguir refletir, por meio de um modelo computacional baseado em agentes, o ambiente estratégico de ganho de reputação criado pela Pesquisa Focus. Para isso, a presente pesquisa faz uso do processo de formação de expectativas baseado em heurísticas de previsão utilizado por Almeida e Silveira (2017), que por sua vez tomaram como referência o arcabouço proposto por Branch (2004). Os métodos de previsão se baseiam no preditor rígido, no preditor adaptativo e em um modelo vetor autoregressivo (VAR). Adiciona-se ainda uma quarta heurística de previsão que consiste em copiar a mediana das expectativas das instituições que compuseram o *ranking* Top 5 no período anterior, de modo que os agentes que utilizam esse preditor são influenciados pelas expectativas dos agentes, para o mês de referência, que apresentaram maior acuidade nas previsões no mês anterior. A próxima seção se des-

tina, então, a apresentar esses mecanismos de formação de expectativas que serão utilizados como um dos blocos de construção do modelo computacional proposto nos capítulos 4 e 5.

3.2 FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO BASEADA EM HEURÍSTICAS

As heurísticas de previsão aqui propostas para a formação de expectativa de inflação têm como objetivo a previsão do Índice Nacional de Preços ao Consumidor Amplo (IPCA), sendo este utilizado como a medida de referência para a inflação no que segue.

A começar pelo método de previsão mais ingênuo, Branch (2004) apresenta o preditor rígido como um método univariado simples baseado na inflação mais recente para a previsão da inflação no próximo período. Se um agente escolhe utilizar o preditor estático, ele espera que a inflação futura seja a própria inflação presente. Formalmente, os agentes que escolhem o preditor estático formam suas expectativas a respeito da inflação esperada em t baseado na inflação observada no período $t-1$:

$$\pi_t^e = \pi_{t-1}, \quad (3.2)$$

na qual π_t^e é a inflação esperada em t e π_{t-1} é a inflação observada em $t-1$.

Como destaca Branch (2004), o preditor adaptativo também é um método univariado de estimação para a inflação que, embora possa ser considerado mais “s sofisticado” do que o preditor rígido, ele ainda deve ser tratado como um preditor simples. Ao utilizar esse método de previsão, os agentes utilizam de maneira ponderada a inflação passada esperada e os seus erros de previsão para formar suas expectativas. Formalmente, a inflação esperada quando se utiliza esse preditor é dada por:

$$\pi_t^e = \pi_{t-1}^e + \mu(\pi_{t-1} - \pi_{t-1}^e), \quad (3.3)$$

sendo μ um parâmetro a ser estimado pela minimização dos quadrados dos erros de previsões, como determinado a seguir:

$$\mu = \min \left\{ \frac{1}{T} \sum_{t=0}^T (\pi_{a,t}^e - \pi_t)^2 \right\}. \quad (3.4)$$

No qual T é o número de períodos da amostra que começa antes e termina subsequentemente à amostra da pesquisa.

Por fim, os agentes que escolhem o preditor VAR fazem uso de um método multivariado. Como destaca Branch (2004), a definição tradicional de expectativa racional é a esperança matemática condicionada a toda a informação disponível. No entanto, em um mundo onde o conjunto de informação disponível é heterogêneo na população de agentes, podemos utilizar o preditor VAR somente como uma alternativa racionalmente

limitada à expectativa racional. “The VAR predictor is a boundedly rational predictor that is ‘in the spirit’ of rational expectations” (BRANCH, 2004, p. 597).

O modelo VAR estimado na presente pesquisa possui como variável dependente o Índice Nacional de Preços ao Consumidor Amplo (IPCA). Diversos modelos VAR foram estimados com a combinação de algumas variáveis explicativas, e o modelo efetivamente escolhido para a simulação foi aquele que minimizou o erro quadrático médio de previsão. As seguintes variáveis foram combinadas ao IPCA: a variação da taxa de câmbio nominal, a variação da taxa de juros real (taxa Selic deflacionada pelo IGP-M), o hiato do produto (a produção industrial foi utilizada como *proxy* para o produto e o hiato foi extraído pelo filtro HP ⁶), a expectativa de inflação (extraído da média dos respondentes da Pesquisa Focus) e a inflação externa medida pelo índice de *commodities* Brasil (IC-Br). ⁷ O Relatório de Inflação de junho de 2017 e de setembro de 2012 foram utilizados como referência para a escolha das variáveis. A combinação de variáveis efetivamente utilizadas foram aquelas que minimizaram o erro quadrático médio. O modelo de referência pode ser descrito como segue:

$$\pi_t^e = \omega_0 + \omega_1 \sum_{i=1}^n \pi_{t-i} + \omega_2 \sum_{i=1}^n h_{t-i} + \omega_3 \sum_{i=1}^n \pi_{t-i}^{e.mercado} + \omega_4 \sum_{i=1}^n cam_{t-i} + \epsilon_t, \quad (3.5)$$

em que ω_0 é a constante da regressão; π é a inflação medida pelo IPCA; h_{t-i} é o hiato do produto; $\pi_{t-i}^{e.mercado}$ é a inflação esperada pelo mercado com um período de defasagem em relação à publicação do indicador; cam_{t-i} é a variação da taxa de câmbio nominal; e o ϵ_t é o resíduo da regressão. O número de defasagens ótimas (i) foi escolhido por meio do critério de informação de Akaike (AIC) para cada período de previsão. Os parâmetros do modelo VAR, por sua vez, foram atualizados em cada período da simulação de modo a englobar as novas informações a respeito das variáveis explicativas utilizadas na estimação.

Segundo Branch (2004), esse conjunto de preditores são escolhidos pela sua longa história e proeminência na pesquisa macroeconômica dinâmica.

Além dos preditores destacados por Branch (2004), no modelo computacional aqui proposto os agentes também poderão escolher usar como método de previsão a mediana das expectativas da inflação para t dos agentes que compuseram o *ranking* Top 5 em $t-1$, isto é, dos agentes que foram classificados no *ranking* Top 5 (no modelo computacional elaborado) baseado nos erros das projeções de $t-1, t-2, t-3, \dots, t-6$. Nesse caso, a expectativa do agente em t é formada por:

$$\pi_t^e = \pi_t^{etop5_{t-1}}, \quad (3.6)$$

⁶ Proposto por Hodrick e Prescott (1997).

⁷ O BCB, em decorrência do efeito que variações nos preços das *commodities* têm desempenhado sobre a dinâmica da inflação doméstica, vem utilizando um indicador de preço de *commodities* para a inflação externa, de acordo com o Relatório de Inflação de junho de 2017, disponível em <https://www.bcb.gov.br/htms/relinf/port/2017/06/ri201706p.pdf>.

no qual $\pi_t^{etop5_{t-1}}$ é a mediana das expectativas de inflação em t , das instituições (representadas pelos agentes no modelo computacional) que compuseram o *ranking* Top 5 em $t-1$.

Esse último preditor é possível de ser utilizado pois o BCB disponibiliza séries diárias da mediana das previsões dos Top 5, e existe um intervalo entre o dia em que é anunciado as instituições top 5 do mês anterior (assim como suas expectativas para o inflação do mês corrente) e o dia da data de referência para o cálculo do *ranking* Top 5 do mês corrente, abrindo-se, assim, a possibilidade de “imitação” das expectativas das instituições Top 5 entre os participantes da Pesquisa Focus.

O processo de formação de expectativas da Pesquisa Focus, interesse central deste trabalho, fará uso do arcabouço utilizado por Branch (2004), que por sua vez foi aplicado para estudar o processo de formação de expectativas no Brasil por Almeida e Silveira (2017).

No próximo capítulo será apresentado um modelo de escolha discreta que considera um ambiente em que os agentes escolhem uma heurística de previsão apenas baseado na acurácia do preditor, não considerando, portanto, o ambiente de competição gerado pelo ganho reputacional de se estar no *ranking* Top 5 da Pesquisa Focus. A três heurísticas de previsão utilizadas no capítulo 4 são as mesmas utilizadas por Almeida e Silveira (2017), sejam elas, o preditor rígido, o preditor adaptativo e o preditor VAR. Já no capítulo 5 propõe-se um ambiente em que os agentes se deparam com a posição no *ranking* Top 5 do BCB como uma forma de incentivo para a escolha do melhor método de previsão, e adiciona-se ainda um quarto método de previsão que consiste em imitar a mediana das expectativas das instituições (agentes) Top 5.

4 FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO DE CURTO PRAZO COMO UM PROCESSO DE ESCOLHA DISCRETA

O modelo explorado neste capítulo se assemelha ao elaborado por Almeida e Silveira (2017) e engloba a formação de expectativas de inflação de curto prazo, em que os agentes possuem como incentivo privado a acurácia que eles obtêm ao utilizar um determinado preditor. O curto prazo se refere à expectativa de inflação feita com um período de defasagem e relação à publicação do indicador. Os agentes possuem uma utilidade determinística que diminui com o aumento do erro quadrático de previsão e com o custo médio do preditor, igual para todos os agentes que usam o mesmo preditor. Além da utilidade determinística, há também um componente aleatório na função utilidade que faz com que o custo total para cada agente possa ser menor ou maior do que o custo médio, devido à heterogeneidade das habilidades cognitivas.

Almeida e Silveira (2017) destacam que a primeira pesquisa que mostrou a heterogeneidade inflacionária como uma propriedade endógena do modelo foi a de Brock e Hommes (1997). Por meio da abordagem *Adaptively Rational Equilibrium Dynamics (ARED)*, Brock e Hommes (1997) elaboraram um modelo de escolha discreta em que os agentes têm a opção de utilizar um preditor de expectativas racionais, com maior custo, ou empregar um preditor de expectativas estáticas, com menor custo. A escolha é feita de forma racional com base no desempenho passado desse preditor e o custo de utilizá-lo. Os autores encontram um equilíbrio instável para o modelo. Caso a economia esteja próxima ao equilíbrio, com quase todos os agentes utilizando o preditor mais simples (de expectativas estáticas), os preços irão divergir do seu valor de estado estacionário e o erro de previsão do preditor simples vai aumentar. Como resultado, os agentes estarão dispostos a pagar o custo de informação do preditor mais sofisticado (de expectativas racionais) e o número de agentes utilizando este último preditor irá aumentar. Com isso, os preços voltarão para o seu valor de estado estacionário. Com os preços próximos ao nível de estado estacionário, o erro de previsão do preditor simples se torna baixo e passa a não ser vantajoso utilizar o preditor mais sofisticado, pelo seu custo de informação associado. Os agentes então voltam a utilizar o preditor simples com maior frequência, e o processo se repete. Almeida e Silveira (2017) apontam que, desde sua introdução em 1997, a abordagem *ARED* tem sido utilizada por diversos autores em diferentes contextos econômicos.

O modelo apresentado e analisado no presente capítulo, por sua vez, tomando como base o elaborado por Almeida e Silveira (2017), e fazendo uso da abordagem *ARED*, supõe que os custos de informação são heterogêneos entre os agentes. Em outros termos, o modelo computacional aqui proposto formaliza um ambiente de interação estratégica composto por agentes com racionalidade limitada e heterogêneos com respeito a suas habilidades cognitivas.

O restante deste capítulo está estruturado como segue. Na seção 4.1 é apre-

sentada a estrutura do modelo de escolha discreta, que será utilizada para representar o processo de formação de expectativas. A seção 4.2 apresenta a estrutura do modelo que representa o processo de escolha discreta baseada em heurísticas de previsão, sendo descrito as preferências dos agentes e a forma como foi calculada a propensão à escolha de cada heurística de previsão. A seção 4.3 mostra a forma como o modelo proposto foi implementado computacionalmente, o método de calibração utilizado, os parâmetros efetivamente encontrados após a calibração e a análise de sensibilidade desses parâmetros. Por fim, as propriedades emergentes do modelo são mostradas na seção 4.4.

4.1 ESTRUTURA GERAL DE UM MODELO DE ESCOLHA DISCRETA

O modelo apresentado a seguir segue a literatura de modelos de escolha discreta descrito em Train (2009). A estrutura apresentada nesta seção se assemelha à utilizada por Almeida e Silveira (2017) para tratar da formação de expectativas como um processo de escolha discreta baseada em heurísticas de previsão, sendo este último trabalho utilizado como base para a elaboração do modelo de formação de expectativa de inflação, assim como o modelo de escolha estratégica associado à Pesquisa Focus, a ser apresentado no próximo capítulo.

Considere um agente $i \in \{1, 2, 3, \dots, A\}$, sendo A o número de agentes. Cada um desses agentes, a cada período de tempo t , pode escolher uma alternativa, mutuamente excludente, de um campo de escolha finito $S = \{1, 2, 3, \dots, M\} \subset \mathbb{N}$, no qual M é o número de alternativas disponível à escolha dos agentes. Seja $\sigma_i \in S$ a escolha do i -ésimo agente em um determinado período. Conforme exposto em Train (2009), a função utilidade pode ser expressa por um componente determinístico, denotado por $U^d(\sigma_i)$, associado às motivações observáveis, e um componente aleatório, denotado por $\zeta(\sigma_i)$, referente às motivações não observáveis do i -ésimo agente ¹, ou seja:

$$U(\sigma_i) = U^d(\sigma_i) + \zeta(\sigma_i). \quad (4.1)$$

Por sua vez, supõe-se que a escolha do i -ésimo agente deverá ser a alternativa que lhe fornece a maior utilidade dentre as alternativas disponíveis a ele. Definido as possibilidades de escolha dos agentes e a função utilidade de cada um, pode-se estabelecer a escolha ótima de cada indivíduo maximizador de utilidade como a alternativa $\sigma_i \in S$ que atente à seguinte desigualdade:

$$U(\sigma_i) \geq U(\sigma'_i), \forall \sigma'_i \in S. \quad (4.2)$$

Usando (4.1), o critério para a escolha ótima (4.2) pode ser definido como segue:

$$U^d(\sigma_i) - U^d(\sigma'_i) \geq \zeta(\sigma'_i) - \zeta(\sigma_i), \forall \sigma'_i \in S. \quad (4.3)$$

¹ O atributo não observável faz com que a tomada de decisão do i -ésimo agente seja um evento aleatório para um observador.

Considerando-se (4.3), mesmo que a utilidade observada da estratégia σ_i seja maior que a utilidade observada da i -ésima estratégia alternativa σ'_i , ou seja, mesmo que $U^d(\sigma_i) - U^d(\sigma'_i) > 0$, a estratégia σ_i não necessariamente será a escolhida pelo agente i . Esta possibilidade existe porque os atributos não observáveis de pelo menos uma das outras estratégias alternativas σ'_i podem assumir um valor que compense o ganho líquido relacionado aos atributos observáveis da estratégia σ_i .

Dada a presença de um componente aleatório na função utilidade, pode-se apenas conhecer a propensão à escolha do agente i para cada um dos preditores. Utilizando as desigualdades (4.2) e (4.3), forma-se a seguinte probabilidade de escolha da estratégia σ_i pelo agente i :

$$\begin{aligned} Prob(\sigma_i) &= Prob(U(\sigma_i) \geq U(\sigma'_i), \forall \sigma'_i \in S) \\ &= Prob(\zeta(\sigma'_i) - \zeta(\sigma_i) \leq U^d(\sigma_i) - U^d(\sigma'_i), \forall \sigma'_i \in S) \\ &= \int_{-\infty}^{\infty} I[\zeta(\sigma'_i) - \zeta(\sigma_i) \leq U^d(\sigma_i) - U^d(\sigma'_i), \forall \sigma'_i \in S] f(\vec{\zeta}_i)(d\vec{\zeta}_i), \end{aligned} \quad (4.4)$$

na qual $I[\cdot]$ é a função indicadora que assume o valor 1 se a expressão entre colchetes for verdadeira e zero caso contrário, e $f(\vec{\zeta}_i)$ é a função densidade de probabilidade conjunta do vetor de variáveis aleatórias $\vec{\zeta}_i$, composto pelas variáveis aleatórias $\zeta(\sigma_j)$, com $\sigma_j \in S$.

Como salientado por Train (2009), diferentes especificações para $f(\vec{\zeta}_i)$ podem ser utilizadas para dar mais estrutura ao modelo de escolha discreta. Existem algumas especificações que são mais convenientes por levarem a uma forma fechada para a integral em (4.4). Uma delas é o modelo logit. Sob tal especificação, os componentes aleatórios da função de utilidade (4.1) são variáveis aleatórias independentes e com a mesma distribuição de probabilidade de valores extremos, que possui função densidade de probabilidade Gumbel (ou valor extremo do tipo I), dada por:

$$f(\zeta(\sigma_j)) = \beta e^{-\beta\zeta(\sigma_j)} e^{-e^{-\beta\zeta(\sigma_j)}}, \quad (4.5)$$

sendo a função de distribuição acumulada associada a ela dada por:

$$F(\zeta(\sigma_j)) = e^{-e^{-\beta\zeta(\sigma_j)}}. \quad (4.6)$$

Utilizando (4.5) e (4.6) podemos resolver (4.4) para encontrar a propensão à escolha do i -ésimo agente como a função de distribuição acumulada logística:

$$\begin{aligned} Prob(\sigma_i) &= \frac{e^{\beta U^d(\sigma_i)}}{\sum_{\forall \sigma'_i \in S} e^{\beta U^d(\sigma'_i)}} \\ &= \frac{1}{1 + \sum_{\forall \sigma'_i \in S, \sigma'_i \neq \sigma_i} e^{-\beta[U^d(\sigma_i) - U^d(\sigma'_i)]}}, \end{aligned} \quad (4.7)$$

na qual $\beta > 0$ é uma constante real que representa a *intensidade de escolha*. Conforme salienta Hommes (2013), para valores extremamente baixos de β , isto é, se $\beta \rightarrow 0$, as probabilidades de escolha das estratégias tornam-se as mesmas, independentemente do valor assumido pelas utilidades determinísticas. Por outro lado, para valores extremamente altos de β , ou seja, se $\beta \rightarrow \infty$, a escolha da alternativa $\sigma_i \in S$ será quase certamente a escolhida se apresentar a maior utilidade determinística. Em outros termos, como a função (4.7) é estritamente crescente com relação a beta, quanto maior a intensidade de escolha, maior a influência do diferencial dos incentivos observados sobre a escolha dos agentes. Como afirma Branch (2004), um valor finito da *intensidade de escolha* poderia ser uma explicação para a rejeição da racionalidade plena nos dados da pesquisa sobre as expectativas de inflação.

Na próxima seção, será utilizada a estrutura analítica do modelo de escolha discreta exposto nesta seção para representar o ambiente de formação de expectativas de inflação de curto prazo.

4.2 ESTRUTURA E PARAMETRIZAÇÃO DO PROCESSO DE ESCOLHA DISCRETA ASSOCIADO À FORMAÇÃO DE EXPECTATIVAS DE CURTO PRAZO

Com intuito de analisar as implicações sobre o processo de formação de expectativas de inflação decorrentes da inserção da Pesquisa Focus, nesta seção apresenta-se um modelo computacional de formação de expectativas com hierarquia de custos a ser utilizado como referência no próximo capítulo.

Considere um ambiente estratégico de formação de expectativas em que, a cada período de tempo t , os agentes possuem o incentivo privado de escolher o melhor mecanismo de previsão avaliando os benefícios (acurácia) do preditor e o custo de utilizá-lo. Seguindo Almeida e Silveira (2017), assume-se que cada agente pode escolher entre três mecanismos de previsão, a saber, os preditores estático, adaptativo e VAR, os quais foram detalhados na seção 3.2. O quarto método de previsão descrito na seção 3.2 (copiar a mediana das previsões, para t , dos agentes que foram Top 5 em $t-1$) só será utilizado no capítulo 5, como forma de refletir o ambiente que as instituições participantes da Pesquisa Focus se deparam.

Considere $\sigma_i \in \{1, 2, 3\}$ a escolha do agente i . Por sua vez, $\sigma_i = 1$ se o agente i escolhe prever por meio do preditor estático; $\sigma_i = 2$ se o agente i escolhe prever por meio do preditor adaptativo; e $\sigma_i = 3$ se o agente i escolhe prever por meio do preditor VAR.

A cada período t , a escolha do i -ésimo agente deverá ser a alternativa $\sigma_i \in \{1, 2, 3\}$ que lhe fornece a maior utilidade. Essa utilidade depende de um atributo observável e também depende de motivações não observáveis, provenientes de características idiossincráticas de cada agente. No presente estudo, as motivações não observáveis estão associadas à capacidade cognitiva de cada agente de extrair e

processar as informações.

A função utilidade determinística (atributo observável) apresentado na seção anterior é composta por incentivos privados que, no presente contexto, advém da acuidade do preditor e do custo médio de utilizá-lo. Esta função utilidade se assemelha à utilizada por Almeida e Silveira (2017), que por sua vez se inspiraram em Branch (2004). Ademais, o custo associado à utilidade determinística será igual para todos os agentes que estiverem usando o mesmo preditor. A estrutura de custo se diferencia da utilizada por Almeida e Silveira (2017) por considerar que os custos crescem em progressão geométrica, sendo o menor custo associado ao preditor rígido, seguido pelo preditor adaptativo, e assumindo o maior valor possível no preditor VAR. Assim, a utilidade determinística do agente i no período t , para $\sigma_i \in S$, pode ser expressa como segue:

$$U_i^d(\sigma_{i,t}) = -[C(\sigma_{i,t}) + (\pi_{i,t}^e(\sigma_{i,t}) - \pi_{i,t})^2], \quad (4.8)$$

no qual $\pi_{i,t}^e(\sigma_{i,t})$ é a previsão da inflação para t que depende da estratégia $\sigma_{i,t}$ escolhida, $\pi_{i,t}$ é o valor observado da inflação medida pelo IPCA, $C(\sigma_i)$ é o custo médio do preditor e $C(\sigma_i) = C(\sigma_j) \forall \sigma_i = \sigma_j$, já que o custo médio do preditor é o mesmo entre os agentes. Considera-se, então, que o custo total do agente i (soma do custo associado à utilidade determinística com o componente aleatório relacionado à dispersão das habilidades cognitivas) de usar o preditor σ_i pode ser menor, maior ou igual ao custo médio do preditor. Se o custo total do agente i de usar o preditor σ_i for maior do que o custo médio, o componente aleatório da função utilidade $\zeta(\sigma_i)$, que representa as habilidades cognitivas, será positivo. Isso significa que o i -ésimo agente apresentará habilidade cognitiva menor do que a habilidade média da população de agentes. Por outro lado, se o custo total do agente i de usar o preditor σ_i for menor do que o custo médio, o componente aleatório da função utilidade $\zeta(\sigma_i)$, que representa as habilidades cognitivas, será negativo, o que significa que o i -ésimo agente apresentará habilidade cognitiva maior do que a habilidade cognitiva média da população de agentes. Em suma, o custo total para o i -ésimo agente ter adotado o preditor σ_i é $C(\sigma_i) + \zeta(\sigma_i)$.

No modelo proposto por Brock e Hommes (1997), levanta-se a hipótese de uma hierarquia de custo crescente com o nível de sofisticação do preditor. Aqui também será adotada tal hierarquia de custos, ou seja, $C(\sigma_i = 1) \leq C(\sigma_i = 2) \leq C(\sigma_i = 3)$. Propõe-se as seguintes formas funcionais para a função custo:

$$C(\sigma_i = 1) = c, \quad (4.9)$$

$$C(\sigma_i = 2) = c(1 + \alpha), \quad (4.10)$$

$$C(\sigma_i = 3) = c(1 + \alpha)^2, \quad (4.11)$$

sendo c e α constantes reais estritamente positivas.

Depois de estabelecida a função utilidade dada por (4.8), pode-se calcular a propensão à escolha da estratégia $\sigma_{i,t}$ por meio da função (4.7), que na presente circunstância é dada por:

$$Prob(\sigma_{i,t}) = \frac{1}{1 + \sum_{\forall \sigma'_{i,t-1} \in S, \sigma'_{i,t-1} \neq \sigma_{i,t-1}} e^{-\beta \{ [C(\sigma'_{i,t}) + (\pi_{i,t-1}^e(\sigma'_{i,t-1}) - \pi_{i,t-1})^2] - [C(\sigma_{i,t}) + (\pi_{i,t-1}^e(\sigma_{i,t-1}) - \pi_{i,t-1})^2] \}}}. \quad (4.12)$$

A propensão à escolha em (4.12) é uma função de distribuição acumulada logística, obtida considerando as habilidades cognitivas dos agentes formadores de expectativas de inflação como variáveis aleatórias independentes e com a mesma distribuição de probabilidade de valores extremos, que possui função densidade de probabilidade de Gumbel (ou valor extremo do top I), especificada em (4.5). A escolha desta distribuição deu-se principalmente por conveniência analítica.

A adoção da referida suposição sobre a distribuição das habilidades cognitivas dos agentes implica, entretanto, que se está assumindo que tais habilidades não são correlacionadas com o tipo de preditor escolhido, tendo a mesma variância para qualquer que seja o preditor escolhido, nem são correlacionadas entre si no transcorrer do processo de reavaliação e escolha recorrente dos preditores de inflação mais apropriados.

Cabe ainda destacar que o uso da premissa de que o componente aleatório (associado às habilidades cognitivas) tem distribuição de valor extremo significa, como explica Train (2009, p. 39), assumir que este componente é aproximadamente distribuído como uma normal independente. Embora a distribuição Gumbel seja uma aproximação da distribuição normal, ela é caracterizada por caudas levemente mais gordas do que esta última. Assim, a distribuição Gumbel, quando comparada à distribuição normal, permite comportamentos relativamente mais atípicos com maior probabilidade. No presente contexto, por tanto, isto significa maior probabilidade da presença de habilidades cognitivas relativamente mais destoantes da média populacional.

4.3 IMPLEMENTAÇÃO COMPUTACIONAL E CALIBRAÇÃO DO MODELO DE ESCOLHA DISCRETA ASSOCIADO À FORMAÇÃO DE EXPECTATIVAS DE INFLAÇÃO DE CURTO PRAZO

Segundo o BCB, existem cerca de 140 instituições cadastradas na Pesquisa Focus. O modelo computacional exposto na seção 4.2 foi então implementado com 140 agentes. Como forma de definir as condições iniciais do modelo, no primeiro período foram distribuídas aleatoriamente as três estratégias de previsão na população de agentes até que cada uma delas fosse adotada por aproximadamente $\frac{1}{3}$ dos agentes.

Assim, cada estratégia foi distribuída de modo que pelo menos 46 agentes adotassem cada uma destas, e para os dois agentes restantes foi alocado aleatoriamente uma das três estratégias. Lembra-se que as três estratégias de previsão consistem em realizar projeções por meio do preditor rígido ($\sigma_i = 1$), do preditor adaptativo ($\sigma_i = 2$) ou do preditor VAR ($\sigma_i = 3$). Após estabelecida as condições iniciais, os agentes calculam suas utilidades determinísticas com base na expressão (4.8). Depois de calculada as utilidades para o período, calcula-se por (4.12) as propensões a escolha de todos os agentes para cada alternativa no campo de escolha $\{1,2,3\}$.

Tendo sido calculada as propensões à escolha do i -ésimo agente, pode-se ordená-las em um segmento de reta no intervalo $[0, 1] \subset \mathbb{R}$. O comando *rand* do *MatLab* é utilizado para gerar um número aleatório $r \in [0, 1] \subset \mathbb{R}$ a partir de uma distribuição uniforme. A escolha do i -ésimo agente em $t = 2$ pode ser especificada por meio do Quadro 2.

Quadro 2 – Algoritmo de escolha do preditor de um agente para $t = 2, 3, \dots, 218$

Casos Possíveis	Escolha do agente i em $t=2$
Caso 1: $r \leq Prob(\sigma_{i,t} = 1)$	Prever por meio do preditor rígido
Caso 2: $Prob(\sigma_{i,t} = 1) < r \leq Prob(\sigma_{i,t} = 1) + Prob(\sigma_{i,t} = 2)$	Prever por meio do preditor adaptativo
Caso 3: $r > Prob(\sigma_{i,t} = 1) + Prob(\sigma_{i,t} = 2)$	Prever por meio do preditor VAR

Fonte: Elaboração própria.

O mesmo procedimento é realizado para todos os períodos subsequentes, sendo a simulação composta por um total de 218 períodos. Optou-se por utilizar o primeiro período da simulação referente ao primeiro mês de 2001, ano em que começou a ser calculado o *ranking* Top 5 pela Pesquisa Focus, terminando a simulação em fevereiro de 2019, sendo então um total de 218 períodos.

De modo a mensurar os parâmetros α , c e β utilizados nas funções custos (4.9), (4.10) e (4.11) e na função propensão à escolha das estratégias (4.12), respectivamente, que fornecem o melhor grau de ajuste ao modelo, foi aplicado um método de calibração que consiste em encontrar o conjunto de parâmetros que minimiza a soma dos quadrados dos erros de previsão, entre os dados empíricos e os simulados. Os dados empíricos utilizados foram as séries disponibilizadas pelo BCB por meio do *Sistema Gerenciador de Séries Temporais* para a média, a mediana e o desvio padrão das expectativas a respeito do IPCA de instituições cadastradas na Pesquisa Focus.² O BCB disponibiliza séries diárias, mas para a calibração foram utilizadas apenas as expectativas da inflação mensal do dia imediatamente após o anúncio da inflação do mês anterior, ou no dia útil mais próximo. Assim, os agentes podem coletar as

² Disponível em <https://www3.bcb.gov.br/expectativas/publico/consulta/serieestatisticas>.

informações necessárias para realizar as previsões para o próximo período. Os dados utilizados para a calibração vão de janeiro de 2001 até fevereiro de 2019. Em outros termos, a combinação dos valores dos parâmetros α , c e β selecionada foi aquela que minimizou a seguinte função objetivo:

$$\sum_{t=1}^T [(M_t^o - M_t^s)^2 + (MNA_t^o - MNA_t^s)^2 + (D_t^o - D_t^s)^2], \quad (4.13)$$

no qual T é o número de períodos, M^o é a média observada, M^s é a média simulada, MNA^o é a mediana observada, MNA^s é a mediana simulada, D^o é o desvio padrão observado e D^s é o desvio padrão simulado.

Para proceder à minimização, foi utilizado a função *fminsearchbnd* do *MatLab*. A função consiste em escolher de forma aleatória diversas combinações de parâmetros, sendo tais parâmetros encontrados dentro de um limite estabelecido previamente e partindo-se de uma configuração inicial para os mesmos. Utilizando uma primeira combinação aleatória de parâmetros, o algoritmo calcula computacionalmente valores simulados para a média, a mediana e o desvio padrão das expectativas dos agentes. Inserindo os valores empíricos e simulados na função objetivo (4.13) obtém-se o valor desta função associado ao vetor de valores dos parâmetros utilizados. O mesmo cálculo é feito para outra combinação aleatória de parâmetros. Se esta última combinação fornecer uma maior acurácia (menor distância entre as séries simuladas e empíricas), ela é armazenada e a combinação anterior é descartada pela função. O processo se repete para 100.000 diferentes conjuntos de parâmetros ou até que o algoritmo encontre um conjunto que gere uma redução do valor de (4.13) inferior a 0,001.

Foram definidos os seguintes intervalos de valores possíveis para para os parâmetros: $0 \leq \alpha \leq 10$, $0 \leq \beta \leq 60$ e $0 \leq c \leq 1$. Devido à existência de mínimos locais, procurou-se obter a configuração inicial de parâmetros que gerassem, após a finalização do algoritmo, o menor valor para a expressão (4.13). Para isto, 10.000 combinações iniciais foram escolhidas aleatoriamente dentre os valores admissíveis anteriormente especificados. Dentre as 10.000 diferentes combinações iniciais, a melhor configuração encontrada foi: $\alpha = 4,5493$, $\beta = 27,2962$, $c = 0,000006$.

Após proceder a calibração descrita, e utilizando a combinação de parâmetros iniciais referida no parágrafo anterior, a função *fminsearchbnd* selecionou a seguinte combinação de parâmetros:


De modo a averiguar se as projeções geradas pelo modelo computacional conseguem, de certa forma, reproduzir as previsões dos respondentes da Pesquisa Focus, as Figuras 1, 2 e 3 mostram gráficos para a média, a mediana e o desvio padrão das séries observadas e das séries simuladas. As séries foram simuladas utilizando os valores dos parâmetros encontrados na calibração e especificados na Tabela 1. Para gerar esses três gráficos, foi excluído o primeiro período de simulação referente às condições iniciais do modelo.

Tabela 1 – Valores dos Parâmetros calibrados.

Parâmetros	Valores calibrados
Intensidade de escolha (β)	8,7646
Parâmetro da função custo (α)	6,6768
Parâmetro da função custo (c)	0,000039

Fonte: Elaboração própria.

Figura 1 – Média das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.




Fonte: Elaboração própria.

Nas figuras, pode-se constatar que as previsões geradas pelo modelo computacional conseguem, em geral, acompanhar os padrões de variação da média, da mediana e do desvio padrão das previsões observadas na Pesquisa Focus. No entanto, a média e a mediana das previsões do modelo apresentaram, em geral, valores superiores ao observado, indicando que as projeções geradas pelo modelo computacional são maiores do que seus respectivos valores observados.


Por fim, com intuito de analisar a sensibilidade do modelo aos parâmetros calibrados, foram realizadas simulações computacionais para verificar a resposta da função objetivo (4.13) ao se variar individualmente cada um dos parâmetros em torno de seus valores calibrados, mantendo os demais constantes. A sensibilidade da função objetivo ao parâmetro β foi feito variando este de 0 a 100 usando um acréscimo de 0,01, para 10001 valores equidistantes, e mantendo os demais parâmetros constantes (encontrados na calibração). Para cada uma destas 10001 simulações foi calculado o valor da função objetivo (4.13), utilizando-se os 217 últimos passos de cada simulação (foi desconsiderado a primeira observação referente às condi-

Figura 2 – Mediana das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.



Fonte: Elaboração própria.

Figura 3 – Desvio padrão das projeções observadas e simuladas para o modelo de formação de expectativas de curto prazo.



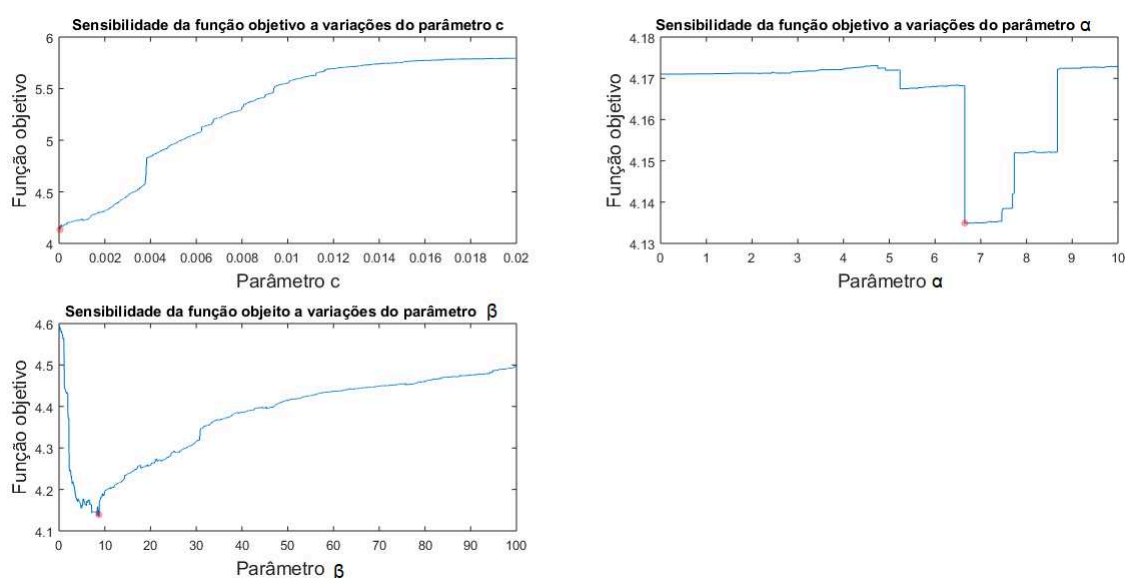
Fonte: Elaboração própria.

ções iniciais). Ou seja, foram extraídos 10001 valores da função objetivo quando $\beta = 0; 0,01; 0,02; 0,03; \dots; 99,98; 99,99; 100$. Um procedimento similar foi feito para os parâmetros α e c , mas variando-os de 0 a 10 e de 0 a 0,02, respectivamente, para 10001 valores equidistantes dos mesmo.

Na Figura 4 observa-se que o modelo é pouco sensível às variações de α

entre 0 e 6,5. O valor da função objetivo (4.13) diminuiu consideravelmente quando o parâmetro α atingiu o valor de 6,6. Entre o mínimo atingido e 7,5 o modelo novamente se mostrou pouco sensível e, após 7,5, a função objetivo apresenta uma trajetória crescente. O modelo também se mostrou consideravelmente sensível às variações do parâmetro β abaixo de 5, sendo este pouco sensível às variações de β entre 5 e 9. Por fim, a função objetivo enfrenta uma trajetória crescente para valores do parâmetro c maiores que 0,000039.

Figura 4 – Sensibilidade da função objetivo às variações dos parâmetros α , β e c para o modelo de formação de expectativas de curto prazo.



Fonte: Elaboração própria.


4.4 PROPRIEDADES EMERGENTES

São mostrados, nesta seção, alguns resultados que emergiram do modelo computacional descrito na seção anterior usando como referência, salvo menção do contrário, os parâmetros encontrados na calibração do modelo, a condição inicial estabelecida na seção 4.3 e os 218 passos da simulação.

A proporção de agentes que utilizam cada preditor pode ser vista na Figura 5. Nela, a linha de cor azul representa a proporção de agentes que utilizam o preditor estático. A linha de cor vermelha representa a soma da proporção dos agentes que utilizam o preditor estático e a proporção dos agentes que utilizam o preditor adaptativo, logo a proporção de agentes que utilizam o preditor adaptativo é a representada pela distância entre a linha vermelha e a linha azul. Por fim, a distância entre a linha verde e a linha vermelha representa a proporção de agentes que utilizam o preditor VAR.

Observa-se que não existe uma estratégia utilizada predominantemente ao longo do tempo na população de agentes, porém existem períodos em que quase a totalidade dos agentes utilizam o preditor VAR, assim como existem períodos em que quase a totalidade dos agentes utilizam o preditor rígido ou o preditor adaptativo. Em média, 29,88% dos agentes utilizam o preditor rígido, 30,35% dos agentes utilizam o preditor adaptativo e 39,76% dos agentes utilizam o preditor VAR.

Figura 5 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo.




Fonte: Elaboração própria.

Dada a referida proporção média de agentes que utilizam cada preditor, constata-se que essa aumenta com o nível de sofisticação do preditor. Isto é, o preditor que apresentou o menor erro quadrático médio (preditor VAR) foi, em média, o mais utilizado entre os agentes e o preditor que apresentou o maior erro quadrático médio (preditor rígido) foi, em média, o menos utilizado entre os agentes.

Para avaliar se a persistência da heterogeneidade de escolhas, vista na Figura 5, não é consequência da distribuição inicial equitativa das estratégias de previsão, foi realizado um teste alterando as condições iniciais das simulações. A Figura 6 mostra os 218 passos da simulação gerados com a condição inicial de que todos os agentes utilizam o preditor rígido. Já a Figura 7 mostra os 218 passos da simulação gerados com a condição inicial de que todos os agentes utilizam o preditor adaptativo, enquanto a Figura 8 mostra os mesmos passos da simulação com a condição inicial de que todos os agentes utilizam o preditor VAR.

Nas Figuras 6, 7 e 8 observa-se que, independente da condição inicial escolhida, a heterogeneidade das expectativas ainda assim é uma propriedade emergente do

Figura 6 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor rígido.




Fonte: Elaboração própria.

modelo, ou seja, passado o período referente à condição inicial, nenhuma heurística de previsão se torna dominante em relação a outra.

Por fim, cabe uma última análise do modelo com respeito ao parâmetro β . O referido parâmetro mede a *intensidade de escolha*. Assim, quanto mais alto é o valor de β , maior a probabilidade de escolha do previsor que possui maior utilidade determinística. Portanto, um valor finito para β , no caso deste modelo calibrado em 8,7646, é um indício de existência de heterogeneidade no processo de formação de expectativas inflacionárias de curto prazo.

Ademais, como a utilidade determinística para o modelo em questão depende da acurácia do preditor escolhido no último período, é de se esperar que ao aumentarmos o valor do parâmetro β , mantendo todos os demais constantes, uma fração maior dos agentes passem a utilizar o preditor que possuiu a melhor acuidade em um determinado período e, assim, o desvio padrão das expectativas devem se tornar menores, uma vez que a tendência é que cada vez mais agentes escolham aquele previsor que apresenta maior acuidade. A Figura 9 ilustra o resultado do desvio padrão das expectativas do modelo quando se aumenta o parâmetro β . O gráfico foi feito variando o valor do parâmetro β de 0 a 150, para 151 valores equidistantes do mesmo, mantendo o valor dos demais parâmetros constantes e extraindo a média do desvio padrão das expectativas dos agentes para os últimos 217 períodos. Como era esperado, temos uma trajetória decrescente do desvio padrão para valores cada vez maiores de β . Em particular, para o valor de $\beta = 8,7646$, encontrado na calibração, a média do

Figura 7 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor adaptativo.




Fonte: Elaboração própria.

desvio padrão das expectativas para os 217 períodos considerados é 0,0806. Sendo este valor muito alto em relação ao valor do desvio padrão para valores do parâmetro β acima de 100. Evidenciando, mais uma vez, a heterogeneidade das expectativas dos agentes no modelo computacional elaborado.


No próximo capítulo, a estrutura geral do modelo de escolha discreta apresentada na seção 4.1 é utilizada de modo a refletir o processo de formação de expectativas no ambiente estratégico criado pelo BCB, no qual os agentes possuem o incentivo de fornecer suas melhores projeções para um possível ganho reputacional de estar entre as cinco instituições que mais acertam as projeções da inflação. Ademais, algumas das propriedades agregadas discutidas na literatura são testadas no modelo computacional descrito no próximo capítulo, de modo a verificar se este consegue refletir uma gama de características agregadas das expectativas de inflação da Pesquisa Focus.

Figura 8 – Proporção de agentes que utilizam cada preditor no modelo de formação de expectativas de curto prazo, com a condição inicial de que todos os agentes utilizam o preditor VAR.



Fonte: Elaboração própria.

Figura 9 – Variação do desvio padrão das expectativas ao aumentarmos o valor do parâmetro β .



Fonte: Elaboração própria.

5 PESQUISA FOCUS COMO UM PROCESSO DE ESCOLHA DISCRETA

O modelo proposto no presente capítulo busca refletir, de certa forma, o ambiente competitivo criado pelo BCB para a escolha do *ranking* Top 5. Espera-se que, ao se considerar esse ambiente, a dispersão das expectativas, assim como o erro quadrático médio de previsão, diminuam em relação ao modelo discutido no capítulo anterior. Isto porque, segundo o BCB, a elaboração do *ranking* Top 5, que classifica as instituições baseado no índice de acerto de suas projeções, tem como objetivo incentivar o aprimoramento da capacidade preditiva dos participantes da pesquisa. A Pesquisa Focus, ao introduzir o ranking Top 5, gera um índice de desempenho de projeção que leva em consideração, conforme detalhado na seção 3.1, o desempenho de todos os agentes cadastrados nela, mesmo daqueles que não responderam a pesquisa. Logo, não só o campo de escolha dos agentes é alterado por esta pesquisa, mas também a função utilidade (ou payoff) de cada um destes. Agora, diferentemente do modelo apresentado no capítulo anterior, o payoff de cada participante da pesquisa dependerá não só do preditor escolhido pelo agente, mas também das escolhas de preditores feitas pelos demais agentes. Espera-se que este novo ambiente estratégico afete o desempenho preditivo médio, bem como a dispersão das previsões individuais, de maneira que tais previsões tornem-se mais acuradas e relativamente homogêneas entre si.

A introdução da Pesquisa Focus no ambiente estratégico formalizado na seção 4.2 do capítulo anterior implica a ampliação do campo de escolha dos agentes. Agora, cada agente deve primeiro decidir se responde ou não à Pesquisa Focus e, se decidir respondê-la, qual estratégia de formação de expectativas utilizará (utilizar o preditor estático, adaptativo ou VAR, ou ainda, simplesmente, imitar a mediana das expectativas dos top 5). Cabe ressaltar que a estratégia de previsão de copiar a mediana das previsões do grupo Top 5 teve como inspiração o resultado empírico encontrado por Carvalho e Minella (2012) de que as previsões das instituições que compõem o *ranking* Top 5 influenciam outras previsões.

Para conseguir verificar como a introdução da Pesquisa Focus afeta a racionalidade do processo de formação de expectativas inflacionárias, inicialmente assumir-se-á que a estrutura hierárquica dos custos de predição não é afetada, de maneira que o impacto da variação apenas do parâmetro β , mantendo os demais constantes, possa ser observado. No entanto, no final do capítulo é apresentado os principais resultados do modelo se calibrarmos todos os parâmetros novamente (havendo, portanto, uma mudança nos custos em relação ao modelo do capítulo anterior), de modo a mostrar que os resultados não mudam consideravelmente ao se retirar a restrição de igualdade dos custos dos dois modelos considerados.

Dada a relevância das expectativas para a condução da política monetária, diver-

so são os trabalhos que buscaram analisar características agregadas das expectativas dos participantes da Pesquisa Focus, por meio do banco de dados disponibilizado pelo BCB. Com efeito, o BCB disponibiliza estatísticas de séries diárias das expectativas, sejam elas, a média, a mediana, o desvio padrão, a amplitude, a expectativa máxima, a expectativa mínima e o número de respondentes. Com essa motivação, este capítulo busca ainda verificar se o modelo computacional de formação de expectativas de inflação de agentes com racionalidade limitada, no ambiente competitivo criado pela Pesquisa Focus, consegue refletir algumas das propriedades agregadas relatadas em trabalhos empíricos.

A fim de realizar tais análises, o presente capítulo foi dividido em duas seções. A seção 5.1 adapta a estrutura do modelo computacional de formação de expectativas baseada em heurísticas de maneira a incorporar as novas características estruturais inseridas pela Pesquisa Focus no ambiente estratégico de formação de expectativas de inflação. Além disso, mostra também como o modelo proposto foi implementado computacionalmente. Por sua vez, a seção 5.2 mostra a calibração e as propriedades emergentes do modelo computacional proposto, dando foco nas propriedades emergentes do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus com hierarquia de custos exógenas.

5.1 ESTRUTURA E IMPLEMENTAÇÃO COMPUTACIONAL DO PROCESSO DE ESCOLHA DISCRETA ASSOCIADO À PESQUISA FOCUS

Considere o ambiente estratégico criado pelo BCB para incentivar as instituições participantes da Pesquisa Focus a melhorar suas previsões, de forma a adquirir maior acuidade. A cada período de tempo t , cada agente pode escolher realizar ou não suas projeções para a inflação. Se a instituição escolhe realizar sua projeção, ela deve escolher um dentre os quatro métodos de previsão discutidos na seção 3.2, sejam eles, prever por meio do preditor rígido, do preditor adaptativo, do preditor VAR ou copiar a mediana da previsão dos Top 5. Desse modo, ao se considerar o ambiente estratégico criado pelo BCB, abre-se a possibilidade dos agentes (instituições) escolherem não realizar suas projeções ou utilizar como método de previsão a mediana das expectativas, para o período corrente, das instituições que compuseram o *ranking* Top 5 com um período de defasagem, de modo que duas outras possibilidades de escolha são adicionadas ao modelo de escolha discreta descrito na seção 4.2. Sendo assim, cada instituição possui um conjunto de cinco estratégias (as quatro já citadas na seção 3.2 e a estratégia de não realizar previsões no período) de escolha em cada período ¹.

Formalmente, sejam $S = 1, 2, 3, 4, 5 \subset \mathbb{N}$ o campo de escolha e $\sigma_j \in S$ a escolha

¹ Cabe salientar que a possibilidade de não fazer previsão não foi considerada no modelo proposto no capítulo anterior porque o foco era exclusivamente sobre o processo de escolhas entre preditores em si.

(estado) do agente i . Adotar-se-á a seguinte notação para quando o agente i for um respondente da Pesquisa Focus: $\sigma_i = 1$ se o agente i escolhe prever por meio do preditor estático; $\sigma_i = 2$ se o agente i escolhe prever por meio do preditor adaptativo; $\sigma_i = 3$ se o agente i escolhe prever por meio do preditor VAR; e $\sigma_i = 4$ se o agente i escolhe usar a mediana das previsões dos Top 5 para realizar suas projeções. Se o agente não responder à pesquisa, assume-se que ele não realiza previsões no período considerado. Nesse último caso, $\sigma_i = 5$. A escolha efetivamente feita pelo i -ésimo agente em um determinado período, por hipótese, será a estratégia $\sigma_i \in S$ que lhe apresenta a maior utilidade. Assume-se que, quanto melhor a posição do agente i no *ranking* elaborado para a definição dos Top 5, maior é a utilidade determinística desse agente. A posição de cada agente no *ranking*, por sua vez, depende do algoritmo desenvolvido pelo BCB para definição das instituições que compõem os Top 5, exposto na seção 3.1. A utilidade determinística das instituições depende, então, da penalidade atribuída a elas, que é baseado nas escolhas feitas nos últimos seis meses, bem como o custo médio do previsor (utilizado no último mês). Esse custo será igual para todos os agentes que estiverem usando o mesmo preditor, e o agente que não atualiza suas previsões não possui custo. Considerando o exposto, assumir-se-á que a utilidade determinística do agente i , para $\sigma_i \in S$, será dada pelo negativo da soma destes dois componentes, ou seja:

$$U_i^d(\sigma_{i,t}) = -[C(\sigma_{i,t}) + \psi_{i,t}(\vec{\sigma}_{i,t})], \quad (5.1)$$

na qual $\vec{\sigma}_{i,t} = (\sigma_{i,t-5}, \sigma_{i,t-4}, \sigma_{i,t-3}, \sigma_{i,t-2}, \sigma_{i,t-1}, \sigma_{i,t})$ é o vetor de estratégias utilizadas nos últimos 6 períodos pelo agente i e $C(\sigma_i)$ é o custo médio do preditor ² σ_i .

Assim como no modelo computacional de referência do capítulo anterior, o custo total do agente i de usar o preditor σ_i pode ser menor, maior ou igual ao custo médio do preditor. Se o custo total do agente i de usar o preditor σ_i for maior do que o custo médio, o componente aleatório da função utilidade $\zeta(\sigma_i)$, que reflete o efeito da heterogeneidade das habilidades cognitivas, será positivo. Isso significa que o i -ésimo agente apresentará habilidade cognitiva menor do que a habilidade média da população de agentes. Por outro lado, se o custo total do agente i de usar o preditor σ_i for menor do que o custo médio, o componente aleatório da função utilidade $\zeta(\sigma_i)$ será negativo, o que significa que o i -ésimo agente apresentará habilidade cognitiva maior do que a habilidade cognitiva média da população de agentes. Em suma, o custo total para o i -ésimo agente ter adotado o preditor σ_i é dado pela soma $C(\sigma_i) + \zeta(\sigma_i)$.

Seguindo a motivação da hierarquia de custos apresentada no modelo do capítulo anterior, no presente modelo assume-se a seguinte hierarquia de custos: $C(\sigma_i = 1) = C(\sigma_i = 4) \leq C(\sigma_i = 2) \leq C(\sigma_i = 3)$. A igualdade $C(\sigma_i = 1) = C(\sigma_i = 4)$ se justifica pelo fato de que o nível de dificuldade de se usar o preditor rígido e imitar a medi-

² $C(\sigma_i) = C(\sigma_j) \forall \sigma_i = \sigma_j$, já que o custo médio do preditor é o mesmo entre os agentes.

ana das previsões dos agentes (instituições) que compõem o *ranking* Top 5 com um período de defasagem deve ser aproximadamente o mesmo. Propõe-se as seguintes formas para a função custo:

$$C(\sigma_j = 1) = c, \quad (5.2)$$

$$C(\sigma_j = 2) = c(1 + \alpha), \quad (5.3)$$

$$C(\sigma_j = 3) = c(1 + \alpha)^2, \quad (5.4)$$

$$C(\sigma_j = 4) = c, \quad (5.5)$$

$$C(\sigma_j = 5) = 0. \quad (5.6)$$

Por (5.6) assume-se que a decisão de não responder implica na não necessidade de realizar uma previsão (custo de previsão nulo).

Ademais, o termo $\psi_{i,t}(\vec{\sigma}_{i,t})$ em (5.1) é semelhante ao algoritmo apresentado pelo BCB para a seleção dos Top 5, cuja fórmula (3.1) é repetida aqui por conveniência:

$$\psi_{i,t} = \frac{1}{6} \sum_{N=t-5}^t (1 - j_{iN})(\text{penal.média})_N + j_{iN}[(1 - k_{iN})(\text{penal.máxima})_N + k_{iN}|E_{iN}\pi_N - \pi_N|], \quad (5.7)$$

na qual:

$\psi_{i,t}$ é a penalidade total atribuída à instituição i no mês t ;

N é o mês para o qual o desvio é calculado;

$E_{iN}\pi_N$ é a projeção da instituição i no mês N para a inflação do mês N ;

π_N é o resultado ocorrido da inflação no mês N ;

$(\text{penal.média})_N$ é o desvio absoluto médio das projeções em N em relação ao resultado ocorrido no mês N ;

$(\text{penal.máxima})_N$ é o desvio absoluto máximo das projeções em N em relação ao resultado ocorrido no mês N ;

$j_{iN} = 0$ se o agente i ainda não estiver realizado nenhuma previsão para a inflação nos N períodos considerados para o cálculo do $\psi_{i,t}$, e $j_{iN} = 1$ caso contrário.

$k_{iN} = 0$ se o agente i não tem projeção válida em N , e $k_{iN} = 1$ caso contrário.

Por exemplo, para o cálculo do ψ_i do mês t , a penalidade do agente i no mês $t-4$ que não estiver realizado previsões naquele mês e em $t-5$ será dado pelo desvio absoluto médio das previsões daquele mês (penal. média). Por outro lado, se o agente estiver realizado projeções em $t-5$ mas não estiver realizado em $t-4$, ele receberá em $t-4$ uma penalidade referente ao desvio absoluto máximo das previsões para aquele mês (penal. máxima). O $\psi_{i,t}$ será então a média dos desvios absolutos das

projeções em relação ao valor observado da inflação (ou as penalidades, para os não respondentes) dos meses $t, t-1, t-2, t-3, t-4$ e $t-5$.

Vale ressaltar que a Pesquisa Focus utiliza a seguinte estratégia para o caso de empate no valor das penalidades atribuídas a cada instituição. Após calcular o valor das penalidades dos últimos seis períodos se existissem, por exemplo, 3 instituições empatadas na quarta posição do *ranking*, para o período de referência existiriam 6 instituições Top 5. O mesmo procedimento foi aplicado neste modelo.

Depois de estabelecida a função utilidade dada por (5.1), pode-se calcular a propensão à escolha da estratégia $\sigma_{i,t}$ por meio da função (4.7), que na presente circunstância pode ser expressa por:

$$Prob(\sigma_{i,t}) = \frac{1}{1 + \sum_{\forall \sigma'_{i,t-1} \in S, \sigma'_{i,t-1} \neq \sigma_{i,t-1}} e^{-\beta\{[C(\sigma'_{i,t-1}) + \psi_{i,t-1}(\vec{\sigma}'_{i,t-1})] - [C(\sigma_{i,t-1}) + \psi_{i,t-1}(\vec{\sigma}_{i,t-1})]\}}, \quad (5.8)$$

na qual $\vec{\sigma}'_{i,t-1} = (\sigma'_{i,t-6}, \sigma'_{i,t-5}, \sigma'_{i,t-4}, \sigma'_{i,t-3}, \sigma'_{i,t-2}, \sigma'_{i,t-1})$.

O modelo apresentado anteriormente foi implementado computacionalmente como segue. Foram utilizados 140 agentes³ e as condições iniciais do presente modelo foram estabelecidas de maneira análoga à aplicada no capítulo anterior. Durante os 6 primeiros períodos, distribui-se aleatoriamente quatro estratégias na população de agentes até que cada uma delas seja adotada por $\frac{1}{4}$ dos agentes. As 4 estratégias consistem em realizar projeções por meio do preditor rígido ($\sigma_j = 1$), do preditor adaptativo ($\sigma_j = 2$), do preditor VAR ($\sigma_j = 3$), ou não realizar previsões para o período ($\sigma_j = 5$). Desse modo, no fim do sexto período, pode-se calcular o *ranking* Top 5 por meio do algoritmo semelhante ao utilizado pelo BCB com base nas estratégias estabelecidas para os 6 períodos iniciais. Após estabelecidas as condições iniciais, os agentes calculam suas utilidades determinísticas com base na expressão (5.1). Depois de calculada as utilidades para o período, a função de distribuição acumulada logística dada por (5.8) é usada de modo a mensurar as propensões à escolha de todos os agentes para cada alternativa no campo de escolha $\{1, 2, 3, 5\}$.⁴

Tendo sido calculada as propensões à escolha do i -ésimo agente, pode-se ordená-las em um segmento de reta no intervalo $[0, 1] \subset \mathbb{R}$. Utiliza-se o comando *rand* do *MatLab* para gerar um número aleatório $r \in [0, 1] \subset \mathbb{R}$ a partir de uma distribuição uniforme. A escolha do i -ésimo agente em $t = 7$ pode ser especificada por meio do Quadro 3.

Em $t = 7$, pode-se calcular o novo *ranking* Top 5 desse período, as utilidades e as propensões à escolha das cinco estratégias, ou seja, incluindo a estratégia imitar

³ Segundo o BCB existem aproximadamente 140 instituições que participam da Pesquisa Focus.

⁴ A utilidade para a estratégia $\sigma_j = 4$ (utilizar a mediana das expectativas das instituições que formaram o *ranking* Top 5 no período anterior) ainda não pode ser calculada pois até o período 7 ainda não havia a possibilidade de definir as instituições (agentes) que compunham o *ranking* Top 5.

Quadro 3 – Critério de escolha do preditor para um agente em $t = 7$

Casos Possíveis	Escolha do agente i em $t=7$
Caso 1: $r \leq \text{Prob}(\sigma_{i,t} = 1)$	Prever por meio do preditor rígido
Caso 2: $\text{Prob}(\sigma_{i,t} = 1) < r \leq \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2)$	Prever por meio do preditor adaptativo
Caso 3: $\text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) < r \leq \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3)$	Prever por meio do preditor VAR
Caso 4: $r > \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3)$	Não realizar previsões no período

Fonte: Elaboração própria.

a mediana das previsões dos agentes que compuseram o *ranking* Top 5 do período anterior. Para que seja possível utilizar a mediana das projeções para a inflação em $t = 7$ das instituições que compuseram o *ranking* Top 5 em $t = 6$, é calculado primeiro as propensões à escolha dessas instituições, assim como suas efetivas previsões (sem a possibilidade de utilizar a estratégia de previsão "copiar a mediana das previsões dos Top 5"), para que em seguida possa ser calculado a propensão à escolha de todas as 5 estratégias, para todas as 140 instituições. No Quadro 4, estas possibilidades encontram-se sintetizadas e aplicam-se para $t \geq 8$.

Quadro 4 – Critério de escolha do preditor de um agente para $t \geq 8$

Casos possíveis	Escolha do agente i em $t \geq 8$
Caso 1: $r \leq \text{Prob}(\sigma_{i,t} = 1)$	Prever por meio do preditor rígido
Caso 2: $\text{Prob}(\sigma_{i,t} = 1) < r \leq \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2)$	Prever por meio do preditor adaptativo
Caso 3: $\text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) < r \leq \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3)$	Prever por meio do preditor VAR
Caso 4: $\text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3) < r \leq \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3) + \text{Prob}(\sigma_{i,t} = 4)$	Prever por meio da mediana dos Top 5
Caso 5: $r > \text{Prob}(\sigma_{i,t} = 1) + \text{Prob}(\sigma_{i,t} = 2) + \text{Prob}(\sigma_{i,t} = 3) + \text{Prob}(\sigma_{i,t} = 4)$	Não realizar previsões no período

Fonte: Elaboração própria.

Assim, a partir de $t = 8$, pode-se utilizar a mediana das projeções dos agentes que compuseram o *ranking* Top 5 no período anterior. Isso porque em $t = 7$ são anunciadas a mediana das projeções, para $t = 7$, das instituições que compuseram o *ranking* Top 5 em $t = 6$. Assim, em $t = 7$, pode-se calcular a função utilidade de utilizar a estratégia de copiar a mediana das expectativas dos Top 5, sendo calculada a propensão à escolha desta estratégia por meio da função (5.8), e a escolha efetivamente feita em $t = 8$ dependerá da metodologia de escolha descrita no Quadro 4. O mesmo procedimento é realizado para todos os períodos subsequentes, sendo o período de simulação composto por um total de 218 períodos.

5.2 CALIBRAÇÃO E PROPRIEDADES EMERGENTES DO MODELO DE FORMAÇÃO DE EXPECTATIVAS DE CURTO PRAZO ASSOCIADA À PESQUISA FOCUS

São mostradas, nesta seção, a calibração e as propriedades agregadas do modelo de formação de expectativa associado à Pesquisa Focus, tanto considerando-se a estrutura de custo exógena a esta mudança institucional quanto endógena (i.e., reagindo à mudança no ambiente estratégico de formação de expectativas de inflação gerada pela implementação da referida pesquisa). A estrutura de custos exógena seria uma simples “cópia” dos valores dos parâmetros da função custo encontrados após a calibração do modelo do capítulo anterior (vide Tabela 1 da seção 4.3).

O modelo com estrutura de custos exógenas é utilizado como referência para as principais análises das propriedades emergentes, já que um dos objetivos da presente dissertação é analisar algumas diferenças pontuais que surgem quando se passa a considerar a Pesquisa Focus no processo de formação de expectativas. Em particular, procurou-se analisar a diferença do valor do parâmetro β , que mede a intensidade de escolha, nos dois modelos. Com isso, é mais razoável verificar as diferenças do comportamento do modelo em relação ao parâmetro β se mantivermos os valores dos demais parâmetros constantes. Espera-se que o parâmetro β , que mede a intensidade de escolha, seja maior para o modelo de formação de expectativas associado à Pesquisa Focus, de modo que, ao se considerar o incentivo reputacional de estar no *ranking* Top 5, os agentes tenham mais incentivo a escolher, dados os custos relativos dos preditores, a estratégia que gera o menor erro de previsão, ou seja, a estratégia que lhes forneceu a melhor posição no *ranking* no período anterior. Como consequência, espera-se também que o erro quadrático médio de previsão diminua ao se considerar o ambiente competitivo criado pelo BCB. No entanto, na subseção 5.2.2 são mostrados os parâmetros gerados quando calibramos todos os parâmetros do modelo conjuntamente, assim como também são mostradas as principais propriedades emergentes do modelo, para verificar se haveria alguma mudança significativa nos resultados se não apenas a intensidade de escolha, mas também a estrutura hierárquica de custos reagisse à presença da Pesquisa Focus.

5.2.1 Formação de expectativas de curto prazo associada à Pesquisa Focus com estrutura de custos exógena

5.2.1.1 Calibração e testes de robustez

Para mensurar os parâmetros c , α e β , que se encontram nas funções custos (5.2) a (5.5) e na função de propensão à escolha das estratégias (5.8), optou-se aqui por utilizar os mesmos valores para os parâmetros da função custo (c e α) encontrados na calibração do modelo de formação de expectativas do capítulo anterior e, para

determinar o valor do parâmetro β que fornece o melhor grau do ajuste ao modelo, dado os valores de c e α , foram utilizadas as séries disponibilizadas pelo BCB por meio do *Sistema Gerenciador de Séries Temporais* para a média, a mediana e o desvio padrão das expectativas das instituições cadastradas na Pesquisa Focus. Assim como na calibração do modelo do capítulo anterior, foi utilizado a expectativa de inflação mensal (IPCA) do dia imediatamente após o anúncio da inflação do mês anterior, ou no dia útil mais próximo. O período utilizado foi de janeiro de 2001 até fevereiro de 2019.⁵

O método de calibração proposto para este modelo é o mesmo proposto para o modelo do capítulo anterior, porém utiliza-se os valores dos parâmetros α e c já encontrados no capítulo 4, e procura-se o valor do parâmetro β que minimiza a soma dos quadrados dos erros de previsão, dada por:

$$\sum_{t=1}^T [(M_t^o - M_t^s)^2 + (MNA_t^o - MNA_t^s)^2 + (D_t^o - D_t^s)^2], \quad (5.9)$$

na qual T é o número de períodos, M^o é a média observada, M^s é a média simulada, MNA^o é a mediana observada, MNA^s é a mediana simulada, D^o é o desvio padrão observado e D^s é o desvio padrão simulado.

Utiliza-se a função *fminsearchbnd*⁶ do *MatLab* para proceder a minimização. Devido à existência de mínimos locais, assim como descrito na seção 4.3, foi feito a procura da configuração inicial de parâmetros que gerassem, após a finalização do algoritmo, o menor valor possível para (5.9). Para isto, 1.000 diferentes valores iniciais para o parâmetro β foram escolhidos aleatoriamente no intervalo $[0, 60] \subset \mathbb{R}$. Dentre os 1.000 diferentes valores iniciais do parâmetro β , 33 geraram menor valor para a função objetivo (5.9). Todos eles, após o término do algoritmo *fminsearchbnd*, apresentaram um valor para β igual a 49,97.

A Tabela 2 mostra o valor do parâmetro β do modelo que minimizou a expressão (5.9), assim como o valor dos parâmetros α e c determinados no capítulo anterior.

Como forma de averiguar se as projeções geradas pelo modelo computacional conseguem, de certa forma, reproduzir os padrões apresentados pelas previsões dos respondentes da Pesquisa Focus, as Figuras 10, 11 e 12 mostram gráficos para a média, a mediana e o desvio padrão das séries observadas e simuladas. As séries simuladas foram geradas utilizando os valores dos parâmetros descritos na Tabela 2 e excluindo-se os 6 primeiros períodos, referentes às condições iniciais do modelo. Nestas figuras pode-se constatar que, assim como no caso do modelo do capítulo

⁵ Optou-se por começar a amostra em 2001 pois foi o ano em que a Pesquisa Focus começou a formar os *rankings* Top 5.

⁶ Uma breve descrição da metodologia desta função se encontra na seção 4.3, e o limite estabelecido para o parâmetro β é o mesmo relatado na referida seção, ou seja, β pôde variar no intervalo $[0, 60] \subset \mathbb{R}$.


Tabela 2 – Valores dos Parâmetros calibrados no modelo de formação de expectativas de curto prazo associado à Pesquisa Focus

Parâmetros	Valores calibrados
Intensidade de escolha (β)	49,9758
Parâmetro da função custo (α)	6,6768
Parâmetro da função custo (c)	0,000039

Fonte: Elaboração própria.

anterior, as previsões geradas pelo modelo computacional associado à Pesquisa Focus conseguem, em geral, acompanhar os padrões de variação da média, da mediana e do desvio padrão das previsões observadas na Pesquisa Focus. No entanto, assim como para o modelo descrito no capítulo anterior, as medidas agregadas do modelo computacional apresentaram, em geral, valores superiores ao observado, indicando que a média e a mediana das projeções geradas pelo modelo computacional são maiores do que o observado.


Figura 10 – Média das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.



Fonte: Elaboração própria.

A análise de sensibilidade do modelo ao parâmetro calibrado β foi feita variando este parâmetro de 0 a 150 usando um acréscimo de 0,01. Em outros termos, simulou-se o modelo para 15001 valores equidistantes de beta, iniciando em 0 e terminando em 150. Cada uma destas simulações tomaram as mesmas condições iniciais estabelecidas na seção 5.1, a mesma semente de números aleatórios e rodaram 218 períodos. Para cada uma destas 15001 simulações foi calculado a função objetivo (5.9), utilizando-se os 212 últimos passos de cada simulação. Observa-se na Figura 13 que,

Figura 11 – Mediana das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.



Fonte: Elaboração própria.


para diferentes valores de β , existem vários mínimos locais, evidenciando a necessidade do procedimento feito na calibração para evitar cair em um desses mínimos. O valor que efetivamente minimizou a função objetivo foi 49,9758.

É interessante notar que a Pesquisa Focus criou o *ranking* Top 5 para incentivar as instituições cadastradas no sistema a aprimorarem suas projeções. Por esse motivo, é de se esperar que, ao considerarmos o ambiente competitivo de escolha das instituições com as 5 melhores projeções, o valor do parâmetro β se torne maior. Isso porque, conforme já salientado na seção 4.1, quando $\beta \rightarrow 0$, as probabilidades de escolha das estratégias tornam-se as mesmas, independentemente do valor assumido pelas utilidades determinísticas. Por outro lado, para $\beta \rightarrow \infty$, a escolha da alternativa $\sigma_i \in S$ será quase certamente a escolhida se apresentar a maior utilidade determinística. A utilidade determinística, por sua vez, depende da acurácia das previsões. Então, um maior valor do parâmetro β , que aumentou de 8,7646 para 49,9758, é um indício de que o processo de escolha das estratégias de previsão se tornou mais eficaz quando passamos a incluir o ambiente competitivo criado pela Pesquisa Focus no modelo computacional.

5.2.1.2 Propriedades emergentes do modelo computacional e padrões empíricos detectados pela literatura

São mostrados, nesta subseção, alguns resultados que emergiram do modelo computacional proposto usando como referência, salvo menção do contrário, os parâmetros encontrados na calibração do modelo (mostrados na Tabela 2), as condições

Figura 12 – Desvio padrão das projeções observada e simulada do modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.




Fonte: Elaboração própria.

iniciais estabelecidas na seção 5.1 e os 218 passos da simulação.

A proporção de agentes respondentes e não respondentes pode ser vista na Figura 14. Nela, a linha de cor azul representa a proporção de agentes respondentes. Observa-se que, passado o período referente às condições iniciais, a proporção de agentes que não formam previsões oscila aproximadamente em torno de 0,12.

Já a Figura 15 mostra, dentro do grupo dos agentes respondentes e, conseqüentemente, dos que formam previsões, a proporção de agentes que utilizam cada preditor. A linha azul representa a proporção de agentes que utilizam o preditor estático. A linha vermelha se refere a proporção de agentes que utilizam o preditor rígido mais o adaptativo, de maneira que a distância entre a linha azul e a linha vermelha é a proporção de agentes que utilizam o preditor adaptativo. A distância entre a linha verde e a linha vermelha representa a proporção de agentes que utilizam o preditor VAR. Por fim, a distância entre a linha amarela, paralela ao eixo das abcissas, e a linha verde representa a proporção de agentes que seguem a mediana das previsões dos agentes Top 5. Nessa figura, pode-se analisar como os agentes se comportaram em relação à escolha do método de previsão. Observa-se que a heterogeneidade das escolhas é persistente e variante no tempo, mas que nenhuma estratégia se mostrou dominante em relação à outra. Assim, passado os seis períodos referentes às condições iniciais, a proporção de agentes para cada estratégia muda ao longo do tempo, mas oscila em torno de 0,25. No entanto, observa-se períodos em que quase a totalidade dos agentes utilizam o preditor rígido ou adaptativo e períodos em que boa parte deles utilizam o preditor VAR ou simplesmente copiam a mediana dos Top 5. Em média,

Figura 13 – Sensibilidade da função objetivo às variações do parâmetro β no modelo de formação de expectativas de curto prazo associado à Pesquisa Focus.




Fonte: Elaboração própria.

18,22% dos agentes escolheram prever por meio do preditor rígido, 18,84% por meio do preditor adaptativo, 27,89% por meio do preditor VAR, 23,07% copiando a mediana das expectativas dos top 5 e 11,96% escolheram não realizar previsões.


Cabe ressaltar, no entanto, que a porcentagem dos agentes que utilizaram o pre-

Figura 14 – Proporção de respondentes e não respondentes da Pesquisa geradas pelo modelo computacional.



Fonte: Elaboração própria.

Figura 15 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões.

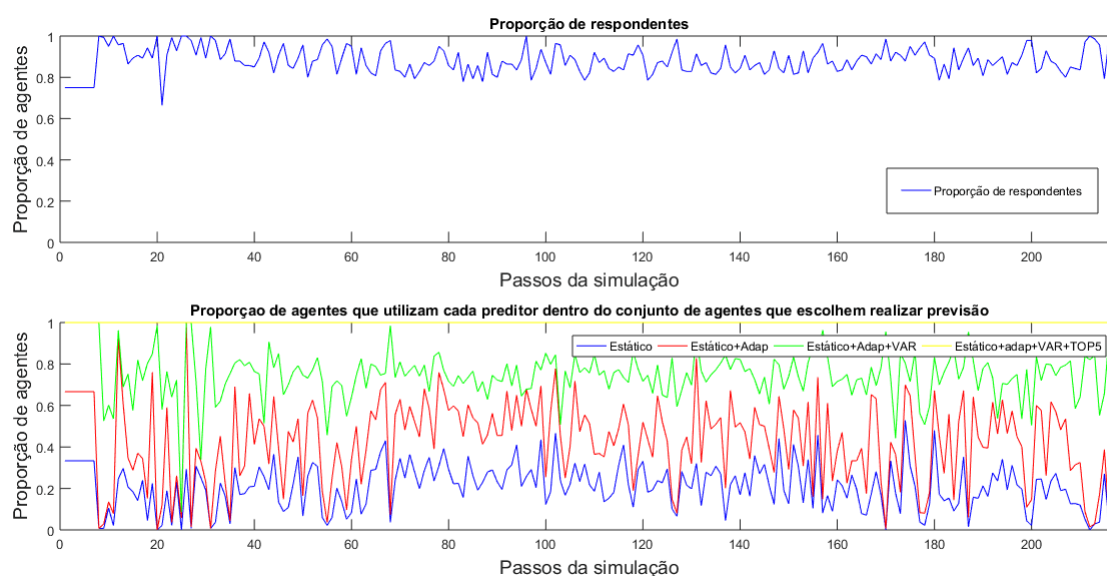


Fonte: Elaboração própria.

ditor rígido, mencionado no parágrafo anterior, pode ser devido ao baixo custo médio dessa estratégia de previsão em relação ao custo do preditor adaptativo e do preditor VAR. Conforme afirma Branch (2004), em alguns momentos, especialmente naqueles de baixa volatilidade da inflação, não vale a pena investir esforço em um método de previsão tecnicamente mais sofisticado se o benefício que esse método provém for inferior ao custo de utilizá-lo. Isto é, quando a diferença na acurácia entre um preditor e outro é muito pequena, tende-se a escolher o preditor com menor custo. Este fator leva à necessidade de se analisar a porcentagem média de agentes que utilizam cada estratégia de previsão ao se desconsiderar o custo médio das estratégias, de modo a verificar se a hierarquia de custos médio é a responsável pela persistência da heterogeneidade das estratégias de previsão de inflação. Assim, o primeiro teste sobre o modelo apresentado consiste em determinar a porcentagem de agentes que utilizam cada estratégia quando os custos médios de previsão são zero. A Figura 16 reproduz esse teste. As frações médias de agentes que utilizam cada estratégia, neste caso, é: 17,83% escolhem prever por meio do preditor rígido, 18,57% escolhem prever por meio do preditor adaptativo, 29,29% escolhem prever por meio do preditor VAR, 22,85% copiar a mediana das expectativas dos Top 5, e 11,46% escolhem não realizar previsões no período. Observa-se que o padrão de escolha se assemelha ao caso com custo médio, mas há um aumento de aproximadamente 2% na porcentagem média de agentes que utilizam o preditor que antes era o mais custoso (preditor VAR), e uma redução próxima a 1% da porcentagem média de agentes que utilizam o preditor rígido. Apesar de haver um aumento da porcentagem média de agentes que escolhem

a estratégia que antes possuía maior custo médio, ainda assim observa-se que existe heterogeneidade nas escolhas das estratégias entre os agentes, indicando que a hierarquia de custos médios não é a responsável pela persistência de heterogeneidade das expectativas de inflação do modelo computacional aqui proposto.

Figura 16 – Proporção de respondentes e não respondentes se todas as estratégias puderem ser adotadas sem custo/Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, quando todas as estratégias podem ser utilizadas sem custo.




Fonte: Elaboração própria.

Ademais, como o BCB disponibiliza séries diárias do número de respondentes de cada indicador, cabe analisar se o número de respondentes do modelo computacional não se diferencia muito em relação ao número de respondentes da Pesquisa Focus. Para o indicador do IPCA, existem informações do número de respondentes a partir de janeiro de 2014. Assim, a Figura 17 procura mostrar que a proporção de agentes respondentes do modelo computacional não se diferencia consideravelmente da proporção de instituições que fornecem suas expectativas de curto prazo para o IPCA. A proporção de instituições respondentes da Pesquisa Focus foi calculado dividindo o número de instituições respondentes no dia da data de referência para o cálculo do *ranking* Top 5 pelo número total de instituições da pesquisa (aproximadamente 140 instituições, segundo o BCB).⁷ Como pode-se observar, a proporção de respondentes, se considerarmos o período de janeiro de 2014 até fevereiro de 2019 (com um total de 62 observações), para o modelo computacional ficou em torno de 90%, e empiricamente essa proporção ficou em torno de 80%.

⁷ O número de instituições respondentes pode ser acessado em <https://www3.bcb.gov.br/expectativas/publico/?wicket:interface=:2:3::..>

Figura 17 – Proporção de respondentes da Pesquisa Focus e do modelo computacional.



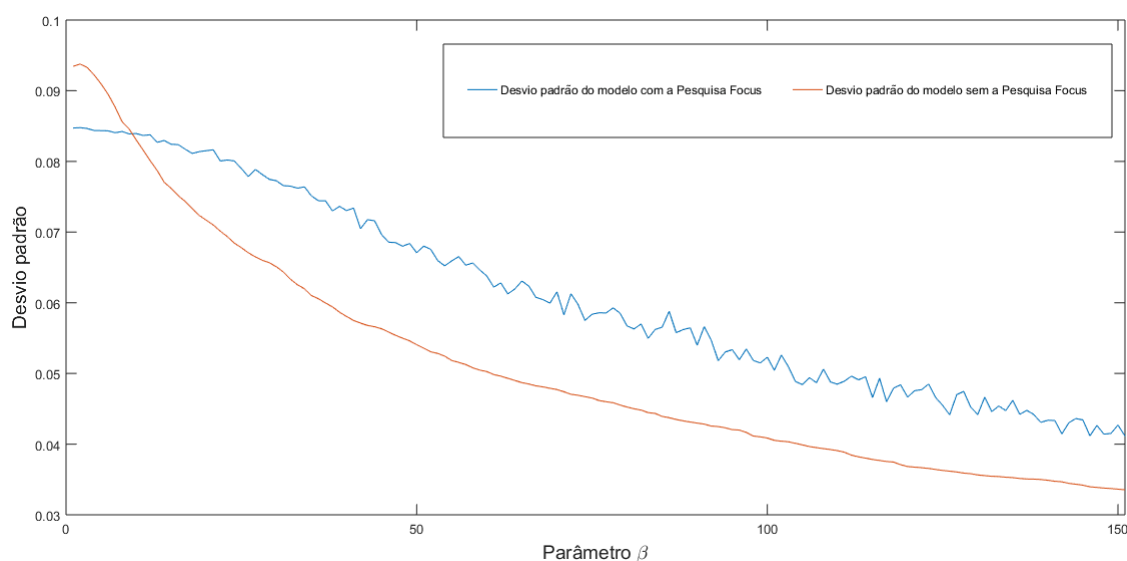
Fonte: Elaboração própria.

Como já salientado anteriormente, o parâmetro β mede a *intensidade de escolha*. Lembrando, para valores baixos de β , as escolhas das estratégias se tornam quase que equiprováveis. Já para valores de β tendendo ao infinito, a escolha da estratégia será quase que certamente a que apresenta maior utilidade determinística. Assim, espera-se que, ao aumentarmos o valor de β , o desvio padrão das expectativas se tornem cada vez menores, uma vez que a tendência é que cada vez mais agentes escolham aquela estratégia que apresenta maior acurácia em um dado período da simulação.

Com essa motivação, a Figura 18 mostra como o desvio padrão das previsões da inflação se comportam com respeito a valores crescentes do parâmetro β . O gráfico foi feito variando o valor do parâmetro β de 0 a 150 usando um acréscimo de 1, para 151 valores equidistantes do mesmo, mantendo o valor dos demais parâmetros constantes e extraindo a média do desvio padrão das expectativas dos respondentes para os últimos 212 períodos, utilizado-se sempre a mesma semente de números aleatórios. Como era de se esperar, temos uma trajetória decrescente para o desvio padrão para valores cada vez maiores de β . A Figura 18 também mostra o caminho do desvio padrão do modelo analisado no capítulo anterior, de modo a se poder realizar duas comparações interessantes entre os dois modelos. Primeiro, observa-se que, para valores de β acima de 10, é necessário um maior valor para esse parâmetro para obter o mesmo desvio padrão nos dois modelos. Esse fato acontece pois, para ambos os modelos computacionais, as diferenças das utilidades determinísticas entre as estratégias de previsão são determinadas pela diferença das acuidades dessas estratégias, porém,

para o caso do modelo computacional deste capítulo, as diferenças das acuidades ao utilizar as diferentes estratégias de previsão no último período é “suavizada” quando se consideram os desempenhos relativos dos agentes nos seis últimos períodos, e não apenas o desempenho estritamente individual (i.e., sem considerar as previsões dos demais agentes) do último período, como no caso do modelo sem a Pesquisa Focus. Segundo, observa-se que ambas as curvas apresentam tendência decrescente. Entretanto, enquanto a curva de cor vermelha apresenta uma queda monotônica do desvio padrão com respeito a β , a outra apresenta flutuações em torno da tendência decrescente. Esse comportamento acontece pois, ao aumentarmos o valor do parâmetro β , há também uma melhora na acurácia de previsão dos Top 5, isso gera uma “disputa” entre a estratégia de previsão que apresentou a melhor acuidade no período anterior e a estratégia de previsão de imitar a mediana dos Top 5, aumentando, para alguns poucos valores maiores de β , as divergências das expectativas.

Figura 18 – Variação do desvio padrão das expectativas de curto prazo ao aumentarmos o valor do parâmetro β nos modelos de formação de expectativas de curto prazo sem e com a Pesquisa Focus.



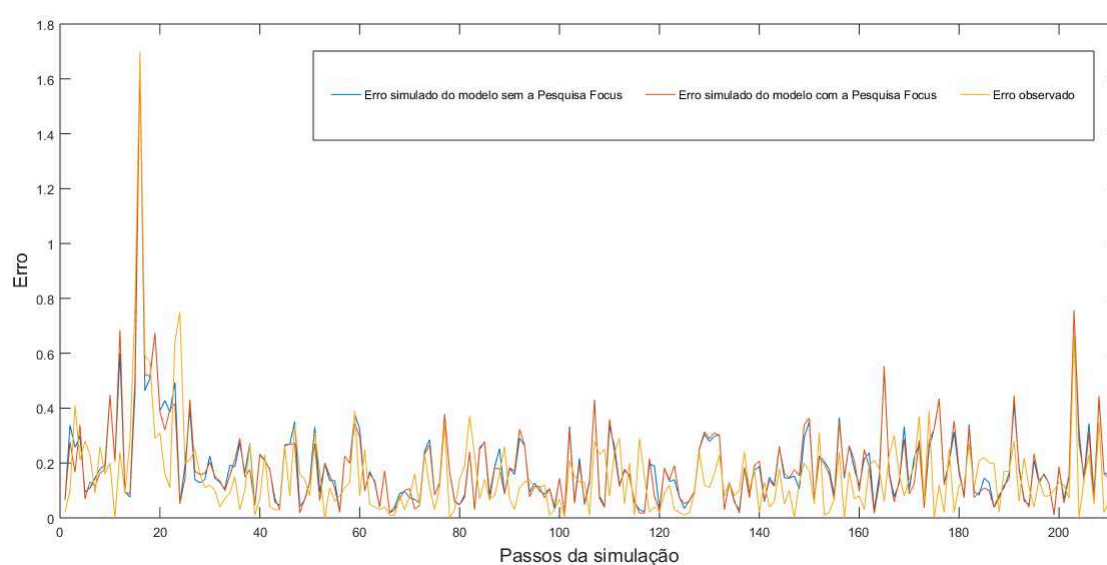
Fonte: Elaboração própria.

Além disso, o desvio padrão médio das expectativas neste modelo de formação de expectativas associado à Pesquisa Focus foi de 0,067, enquanto o desvio padrão das expectativas do modelo do capítulo anterior foi de 0,0806. Esse resultado reforça os indícios de que, ao se considerar o ambiente competitivo de premiação dos Top 5, os agentes tendem a escolher, com maior intensidade, a estratégia de previsão que fornece maior acuidade das projeções.

Ademais, a Figura 19 mostra os erros (desvio absoluto da média das expectativas em relação ao valor observado da inflação) simulados quando se considera e

quando não se considera o ambiente competitivo de premiação dos Top 5, e mostra também os erros empíricos (desvio absoluto da média das expectativas das instituições respondentes da Pesquisa Focus em relação ao valor observado da inflação). A média dos erros quando se considera o ambiente sem a Pesquisa Focus é 0,1904, a média dos erros quando se considera o ambiente com a Pesquisa Focus é 0,1866, enquanto a média dos erros empíricos é 0,1537. Esse resultado indica que o sistema de premiação dos Top 5 tende a melhorar a acuidade das previsões.

Figura 19 – Erros de previsão simulados quando se considera e quando não se considera o ambiente competitivo de premiação dos Top 5 e erros de previsão observados

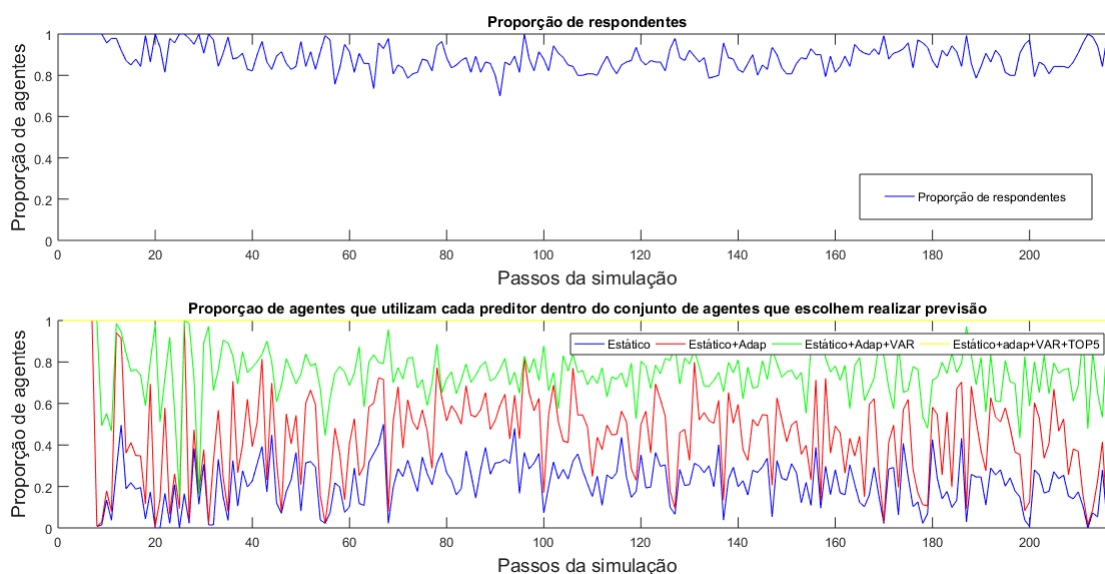


Fonte: Elaboração própria.

Para verificar se a distribuição inicial equitativa entre as quatro estratégias de previsão (prever por meio do preditor rígido, prever por meio do preditor adaptativo, prever por meio do preditor VAR ou não prever) para os 6 primeiros períodos não é a responsável pela persistência da heterogeneidade das escolhas das estratégias, propõe-se um teste em que se verifica a distribuição das estratégias para os casos em que todos os agente, nos 6 períodos iniciais, escolhem prever por meio do preditor rígido, para o caso em que a escolha consiste em prever por meio do preditor adaptativo e para o caso em que a escolha consiste em prever por meio do preditor VAR ⁸. Observa-se nas Figuras 20, 21 e 22 que, passado os períodos iniciais, a distribuição das estratégias se assemelha ao caso em que elas são inicialmente distribuídas na mesma proporção. Portanto, as condições iniciais não parecem afetar o padrão da distribuição em torno do qual o sistema gravita.

⁸ Não é feito o teste para o caso de não haver previsão pois, se assim fosse, não seria possível calcular os Top 5 ao final do período 6, pois nenhum agente teria realizado previsões.

Figura 20 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor rígido.

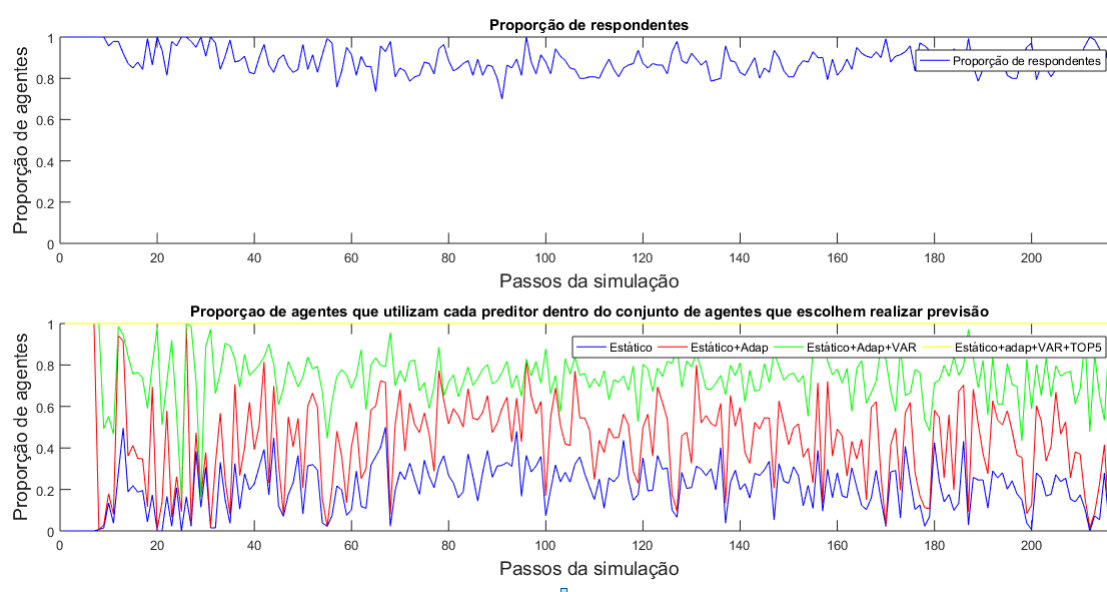


Fonte: Elaboração própria.

Os testes mostrados a seguir procuram verificar se o modelo computacional baseado em agentes com racionalidade limitada, que representa o ambiente estratégico de ganho de reputação, discutido neste capítulo, consegue refletir uma gama de propriedades agregadas exploradas na literatura, que emergiram das séries temporais de expectativas agregadas de curto prazo para a inflação medida pelo IPCA. Para realizar esses próximos testes foram utilizados os parâmetros calibrados descritos na subseção anterior e as expectativas dos Top 5 utilizadas nos testes foram as expectativas formadas, para o período corrente, das instituições que foram classificadas como as Top 5 no período anterior (baseado nas projeções dos últimos 6 períodos). Em outras palavras, em um determinado passo t da simulação foram extraídas as expectativas dos agentes que possuíam em média as 5 melhores previsões (ou menores penalidades) nos últimos seis períodos ($t-1, t-2, \dots, t-6$). Considerou-se essas previsões porque o BCB fornece valores agregados (da média, mediana, desvio padrão, valor máximo e valor mínimo) das expectativas das instituições que foram classificadas como as Top 5 baseado em suas projeções dos últimos 6 períodos anteriores. Essas variáveis disponibilizadas pelo BCB, por sua vez, foram as utilizadas nos trabalhos empíricos destacados no que segue.

Para analisar o comportamento da correlação de variáveis agregadas da Pesquisa Focus, Meurer e Lima (2017) verificaram os coeficientes de correlação entre a mediana agregada das expectativas (MD), a mediana dos agentes que compõem o *ranking* Top 5 (MDtop5), o desvio padrão agregado das expectativas (DP) e o desvio padrão das previsões dos agentes que compõem o *ranking* Top 5 (DPtop5). Os autores

Figura 21 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor adaptativo.



Fonte: Elaboração própria.

utilizaram dados diários de abril de 2010 a agosto de 2016 e os resultados encontrados pelos mesmos se encontram na Tabela 3.


Tabela 3 – Coeficiente de correlação entre a mediana e desvio padrão das expectativas observado

	MD	DP	MDtop5	DPtop5
MD	1			
DP	0,532	1		
MDtop5	0,985	0,516	1	
DPtop5	0,208	0,622	0,206	1

Fonte: Meurer e Lima, 2017, p. 7.

Na Tabela 4 se encontram as mesmas variáveis extraídas dos dados simulados. Para calcular essas correlações foram extraídos a mediana e desvio padrão dos Top 5 e do agregado dos agentes dos últimos 212 passos da simulação. De modo similar ao resultado empírico encontrado por Meurer e Lima (2017) para as expectativas das instituições cadastradas na Pesquisa Focus, observa-se um alto coeficiente de correlação entre a mediana do grupo Top 5 e a mediana agregada, o que indica que este grupo é uma boa aproximação do conjunto dos agentes. Também semelhante ao encontrado por Meurer e Lima (2017), observa-se um coeficiente de correlação positivo entre a mediana do agregado dos respondentes e o desvio padrão das previsões, indicando que, quando há um aumento da mediana das expectativas, a dispersão

Figura 22 – Proporção de agentes que utilizam cada estratégia de previsão, com a condição inicial de que todos os agentes utilizam o preditor VAR.



Fonte: Elaboração própria.

Tabela 4 – Coeficiente de correlação entre a mediana e desvio padrão das expectativas de todos os agentes e do grupo Top 5, para o modelo computacional proposto

	MD	DP	MDtop5	DPtop5
MD	1			
DP	0,2491	1		
MDtop5	0,9884	0,2707	1	
DPtop5	0,1222	0,6602	0,1475	1

Fonte: Elaboração própria.

das previsões é maior. De acordo com Meurer e Lima (2017, p.7), dado a hipótese de maior incerteza nas previsões estar associada com maior taxa de inflação (BALL, 1992; FOUNTAS, 2001), esse resultado é um indício de que a relação entre a incerteza nas previsões existe também para a própria taxa prevista de inflação.

Os referidos autores encontraram um coeficiente de correlação entre a mediana dos Top 5 e o desvio padrão desse grupo igual a 0,206, enquanto a correlação entre a mediana e o desvio padrão do agregado das instituições foi de 0,532. Assim, eles concluíram que existe uma proximidade nas previsões dentro do grupo que mais acerta as projeções. O coeficiente de correlação encontrado no modelo computacional para essas variáveis, apesar de mais baixo que o relatado empiricamente, também é menor do que a mesma correlação para o agregado dos agentes, indicando que, para o modelo computacional desenvolvido neste capítulo, também há uma maior proximidade

nas previsões do grupo que mais acerta em relação ao agregado. Como afirmam Meurer e Lima (2017), vale notar que, como a previsão utilizada para a apuração do *ranking* Top 5 considera as previsões dos 6 períodos anteriores, pode-se concluir que o grupo de instituições que mais acertou no passado permanece tendo baixa divergência nas previsões para o período seguinte.

Outra interessante análise de correlação também relatada por Meurer e Lima (2017) é entre a mediana, a amplitude, o valor máximo, o valor mínimo e o desvio padrão das expectativas do agregado. A Tabela 5 mostra os valores das correlações encontradas pelos autores. Observa-se uma correlação positiva entre a mediana e a amplitude, o valor máximo, o valor mínimo e o desvio padrão, confirmando indícios de que a elevação da inflação prevista é acompanhada por aumento da dispersão das expectativas das instituições participantes da Pesquisa Focus, tanto mensurada pelo desvio padrão quanto pela amplitude das expectativas (diferença entre o valor máximo e o valor mínimo). Os autores utilizaram dados diários de janeiro de 2003 a agosto de 2016. Apesar de o modelo computacional elaborado na presente pesquisa gerar apenas dados mensais, ainda assim foi feito uma análise semelhante utilizando os últimos 212 passos da simulação. Na Tabela 6 encontram-se os resultados dos coeficientes de correlação extraídos do modelo computacional.

Tabela 5 – Coeficientes de correlação entre a amplitude, o valor máximo e mínimo, a mediana e o desvio padrão das expectativas observadas

	Amplitude	Máximo	Mínimo	Mediana	Desvio Padrão
Amplitude	1				
Máximo	0,847	1			
Mínimo	0,205	0,693	1		
Mediana	0,624	0,912	0,835	1	
Desvio Padrão	0,928	0,797	0,209	0,616	1

Fonte: Elaboração própria.

Tabela 6 – Coeficientes de correlação entre a amplitude, o valor máximo e mínimo, a mediana e o desvio padrão das expectativas dos agentes geradas pela simulação

	Amplitude	Máximo	Mínimo	Mediana	Desvio Padrão
Amplitude	1				
Máximo	0,5738	1			
Mínimo	0,0691	0,8567	1		
Mediana	0,2132	0,8750	0,9315	1	
Desvio Padrão	0,9178	0,5636	0,1084	0,2491	1

Fonte: Elaboração própria.

Pode-se observar que o valor dos coeficientes de correlação encontrados no

modelo computacional possuem, em geral, valores menores do que os resultados encontrados para dados reais. A correlação entre a mediana e a amplitude e o desvio padrão extraídas computacionalmente também são positivos, sendo indício de que a elevação da inflação prevista é acompanhada por aumento da dispersão das expectativas. Meurer e Lima (2017) chamam atenção para o fato de que a correlação da amplitude, assim como do desvio padrão, das previsões é elevada com a expectativa máxima e baixa com a expectativa mínima. Os autores afirmaram que isso pode ser um indício de que os previsores pessimistas com a inflação ajustam mais suas previsões, elevando o valor máximo em maior intensidade e reduzindo-o em menor intensidade do que agentes otimistas. Apesar do modelo computacional elaborado não ter como foco a diferenciação entre agentes otimistas e pessimistas, ele também apresenta uma correlação maior entre a expectativa máxima e a amplitude e o desvio padrão do que entre a expectativa mínima e a amplitude e o desvio padrão.

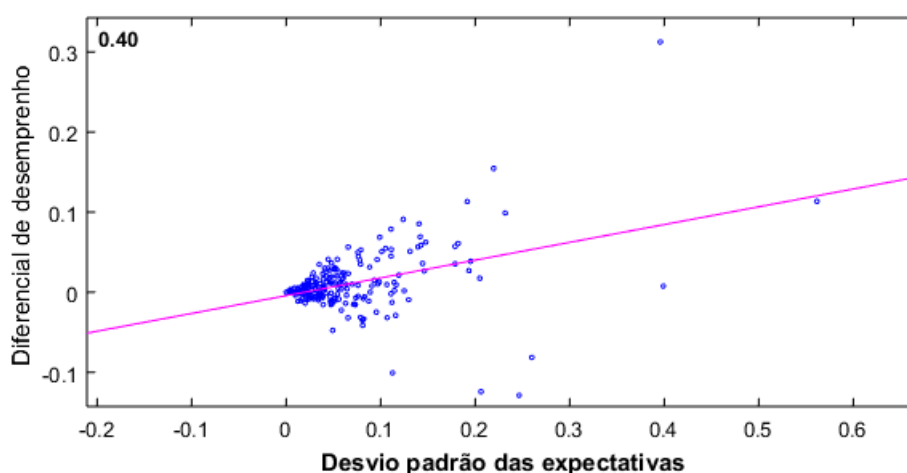
Para comparar o desempenho dos agentes que compõem o grupo Top 5 e o desempenho das previsões dos agentes no agregado, foram avaliados também os erros das projeções dos dois grupos. O referido erro é dado pelo desvio das projeções em relação ao valor observado do IPCA. A simulação computacional, excluindo-se os 6 primeiros períodos referentes às condições iniciais do modelo, mostrou que, em média, os erros médios das previsões do grupo Top 5 foram menores do que os erros médios das previsões dos agentes em geral. Isto é, a média dos módulos dos desvios dos Top 5 foi de 0,176, enquanto que a média dos módulos dos desvios das instituições em geral foi de 0,187. Um resultado semelhante foi encontrado por Prada (2007) ao utilizar o desvio da mediana agregada das projeções dos respondentes da Pesquisa Focus e o desvio da mediana das projeções das instituições que compõem o grupo dos Top 5 da referida pesquisa. A autora encontrou que, para o período que vai de novembro de 2001 a novembro de 2006, a média dos módulos dos erros do grupo Top 5 foi 0,11 e o erro médio de todas as instituições foi 0,14. Esse resultado corrobora a hipótese de que as instituições que mais acertaram no passado, em média, permanecem tendo melhor acuidade nas projeções.

Ademais, considerando-se Prada (2007), espera-se que, em um ambiente de heterogeneidade de expectativas de inflação entre os agentes, quanto maior a dificuldade em se projetar a inflação em um determinado período, mais dispersas tendem a ser as projeções dos participantes. De fato, uma relação positiva entre o diferencial de desempenho do grupo Top 5 em relação ao agregado dos agentes e o desvio padrão deve ser observada, já que o desvio padrão das projeções pode ser utilizado como uma medida do grau de dificuldade da projeção. Em suma, quanto maior a dificuldade em se projetar a inflação em um determinado período, mais dispersas tendem a estar as projeções dos agentes. Para verificar se existe evidência a respeito de tal relação no modelo computacional, foi calculado o coeficiente de correlação entre o diferencial do

desempenho e o desvio padrão gerados por simulação. O diferencial de desempenho foi calculado pela diferença entre a média dos módulos dos desvios das expectativas do agregado dos agentes e dos Top 5 em relação ao valor observado da inflação. O coeficiente de correlação encontrado apresentou um valor de 0,4023, indicando uma relação positiva entre o diferencial dos erros e o desvio padrão simulados. O coeficiente de correlação encontrado por Prada (2007), para o período entre março de 2002 e novembro de 2006, foi 0,65. Ademais, já que a apuração do *ranking* Top 5 considera as previsões com um período de defasagem, o resultado encontrado leva a crer que o grupo de instituições que mais acertou no passado permanece tendo melhor desempenho no próximo período, reforçando que pode ser uma boa estratégia copiar a mediana das expectativas das instituições que foram Top 5 no período anterior.

Na Figura 23 se encontra o gráfico de dispersão entre o diferencial de desempenho e o desvio padrão das expectativas de inflação, gerados pelo modelo computacional. Esse gráfico demonstra a relação positiva entre as duas variáveis analisadas. Enquanto a Figura 24 mostra picos de diferencial de desempenho acompanhados por picos no mesmo sentido do desvio padrão das expectativas simuladas.


Figura 23 – Dispersão entre o diferencial de desempenho e o nível de dificuldade simulados



Fonte: Elaboração própria.

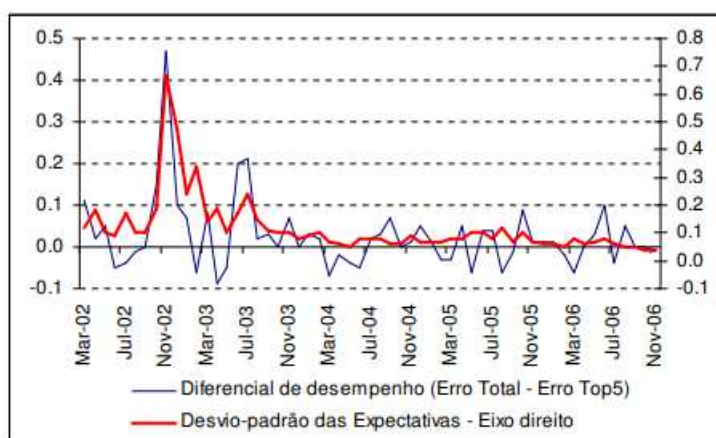
Um gráfico semelhante ao mostrado na Figura 24 foi feito por Prada (2007) com dados observados da Pesquisa Focus, porém utilizando apenas o período que vai de março de 2002 a novembro de 2006. Este se encontra na Figura 25. Observa-se também nesse gráfico picos de diferencial de desempenho acompanhados por picos no mesmo sentido do desvio padrão das expectativas observadas.

Figura 24 – Comparação entre diferencial de desempenho e grau de dificuldade das projeções simuladas



Fonte: Elaboração própria.

Figura 25 – Comparação entre diferencial de desempenho e grau de dificuldade das projeções observadas



Fonte: Prada, 2007, p. 32.

5.2.2 Formação de expectativas de curto prazo associado à Pesquisa Focus com estrutura de custos endógenas

Esta subseção se destina a mostrar que, ao calibrarmos todos os parâmetros conjuntamente e assim possivelmente mudarmos o valor dos custos médios das estratégias de previsão, não há mudança significativa na proporção de agentes que utilizam cada preditor. Lembrando, um foco maior às análises das propriedades emergentes foi dado ao modelo discutido na subseção anterior, pois parece mais razoável avaliar algumas diferenças que surgem quando passamos a considerar a Pesquisa Focus no processo de formação de expectativas se mantivermos a hierarquia de custos constantes. Assim, são mostrados nesta subseção apenas os principais resultados

que emergiram do modelo computacional ao ser calibrado os parâmetros da função custo novamente, de forma a mostrar que, mesmo que deixássemos calibrar todos os parâmetros conjuntamente, os padrões de escolha dos agentes permaneceriam os mesmos.

A metodologia de calibração empregada foi a mesma descrita na subseção anterior. Com isso, a melhor configuração inicial dos parâmetros para começar o algoritmo da função *fminsearch* do *MatLab* foi: $\alpha = 2,1821$, $\beta = 39,6909$ e $c = 0,0042$. Essa combinação foi a que minimizou, após a finalização do algoritmo, a função objetivo (5.9) dentre 5000 combinações iniciais de parâmetros escolhidas aleatoriamente e definidas dentro do limite $0 \leq \alpha \leq 10$, $0 \leq \beta \leq 60$ e $0 \leq c \leq 0,01$.⁹ Por sua vez, os parâmetros efetivamente encontrados após a calibração, utilizando a referida configuração inicial de parâmetros na função *fminsearch* se encontram na Tabela 7.

Tabela 7 – Valores de todos os parâmetros calibrados no modelo associado à Pesquisa Focus

Parâmetros	Valores calibrados
Intensidade de escolha (α)	0,0619
Parâmetro da função custo (β)	42,2145
Parâmetro da função custo (c)	0,0062


Fonte: Elaboração própria.

Percebe-se que houve um aumento no valor do parâmetro c que parece ter sido compensado, de certa forma, por uma redução no valor do parâmetro α . A proporção de agentes respondentes e não respondentes é mostrado na Figura 26, enquanto a Figura 29 mostra qual foi a proporção de escolha dos preditores dentro do conjunto de respondentes. Observa-se que, apesar de haver um aumento no valor do parâmetro c e uma diminuição no valor do parâmetro α , a proporção de agentes que utilizam cada estratégia de previsão não muda consideravelmente quando calibramos todos os parâmetros conjuntamente.

Em média, 17,58% dos agentes utilizam o preditor rígido, 17,95% dos agentes utilizam o preditor adaptativo, 22,51% dos agentes utilizam como estratégia de previsão imitar a mediana das expectativas dos Top 5, 26,51% dos agentes utilizam o preditor VAR e 15,45% dos agentes escolhem não realizar previsões no período. Vale ressaltar que, como o valor do parâmetro c aumentou e o valor do parâmetro β diminuiu em relação ao caso em que consideramos a estrutura de custos exógenas, houve um au-

⁹ O limite para o parâmetro c foi reduzido na calibração deste modelo em comparação ao modelo do capítulo 4 pois, no modelo associado à Pesquisa Focus, para simulações nos limites superiores dos parâmetros α e c descritos no capítulo 4, os custos de responder utilizando qualquer um dos preditores seriam tão grandes que todos os agentes passariam a escolher a estratégia de não responder e, por esse motivo, não haveriam valores de expectativas para comparar com os dados empíricos. Como a Figura 4 apresenta significativo aumento da função objetivo (4.13) para valores altos de c , a diminuição do limite para o referido parâmetro se mostrou uma hipótese razoável.

Figura 26 – Proporção de agentes que escolhem formar previsões no modelo computacional associado à Pesquisa Focus com estrutura de custos endógena.




Fonte: Elaboração própria.

mento significativo da proporção de agentes não respondentes, de aproximadamente 4%. O aumento da proporção de não respondentes pelo aumento do valor parâmetro c se deve ao fato de que a estratégia de não realizar previsões é a única que não possui custo. Portanto, a utilidade determinística de não prever é devido apenas ao erro absoluto máximo das previsões que, em momentos de baixa volatilidade da inflação, tende a ser pequeno. Já o aumento da proporção de não respondentes pela redução do valor do parâmetro β indica que há uma redução da intensidade de escolha de estratégias com maior utilidade determinística.


Mostra-se ainda a distribuição dos preditores entres os agentes para o caso em que todas as estratégias de previsão podem ser utilizadas sem o custo médio. Nesse caso, 18,18% dos agentes utilizam o preditor rígido, 18,60% dos agentes utilizam o preditor adaptativo, 22,61% dos agentes utilizam como estratégia de previsão imitar a mediana das expectativas dos Top 5, 28,09% dos agentes utilizam o preditor VAR e 12,52% dos agentes escolhem não realizar previsões no período. Observa-se que, assim como na subseção anterior, ao desconsiderarmos a estrutura de custos médios, há um aumento na proporção média de utilização das estratégias que antes possuíam maior custo. Em particular, a proporção de agentes que escolhem não realizar previsões (custo igual a zero) diminuiu aproximadamente 3% e a proporção de agentes que utilizam o preditor VAR (maior custo e menor erro quadrático médio de previsão) aumentou aproximadamente 2%.

Figura 27 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, no modelo computacional associado à Pesquisa Focus com estrutura de custos endógena.




Fonte: Elaboração própria.

Figura 28 – Proporção de agentes que escolhem formar previsões no modelo computacional associado à Pesquisa Focus sem a estrutura de custo médio.



Fonte: Elaboração própria.

Figura 29 – Proporção de agentes que utilizam cada preditor, dentro do conjunto de agentes que realizam previsões, no modelo computacional associado à Pesquisa Focus sem a estrutura de custo médio.



Fonte: Elaboração própria.

6 CONSIDERAÇÕES FINAIS

Em geral os modelos macroeconômicos utilizam a hipótese de que as expectativas são racionais e homogêneas. Conforme afirma Hommes (2006), a hipótese de expectativas racionais assume que as previsões dos agentes são perfeitamente consistentes com as realizações e que eles não cometem erros sistemáticos. Em equilíbrio, as previsões sobre variáveis futuras coincide com a esperança matemática, dada toda a informação relevante.

No entanto, a partir do final dos anos 1980, modelos com agentes heterogêneos e racionalidade limitada têm se tornado cada vez mais populares, e cada vez mais economistas questionam a hipótese de racionalidade plena em que os agentes são perfeitamente informados e não possuem limitações de habilidade computacional (HOMMES, 2006).

Como mostrado no capítulo 2, diversas pesquisas apresentaram evidências de existência e persistência de heterogeneidade das expectativas de inflação em dados de pesquisa de opinião de diversos países. Entre as possíveis explicações para tal heterogeneidade persistente se destacam as diferenças nos conjuntos de informação que os indivíduos possuem e as diferenças nas suas habilidades cognitivas de captar e processar informações. Também no capítulo 2 foram mostrados alguns trabalhos empíricos que se dedicaram a analisar os padrões de heterogeneidades das expectativas das instituições participantes da Pesquisa Focus.

Diante disso, a presente dissertação buscou contribuir com a literatura que analisa as expectativas inflacionárias heterogêneas no Brasil por meio da elaboração de um modelo computacional baseado em agentes representando formalmente o ambiente estratégico criado pelo ranking Top 5 da Pesquisa Focus. Ambiente este composto por agentes com habilidades cognitivas heterogêneas e no qual o mecanismo de seleção de métodos de previsão é formalizado como um processo de escolha discreta.

Para representar a heterogeneidade das habilidade cognitivas, o modelo proposto considerou que os custos de formar as expectativas, isto é, o custo de utilizar uma determinada estratégia de previsão, possui um componente determinístico (dado pelo custo médio do preditor) e um componente estocástico (associado à dispersão das habilidades cognitivas). Um modelo de formação de expectativas de curto prazo mais geral, sem considerar a escolha dos agentes com melhores projeções inspirado na Pesquisa Focus, foi mostrado no capítulo 4. Nesse modelo, os agentes possuíam como utilidade determinística de uma determinada heurística de previsão o negativo da soma do custo médio do preditor com o erro de previsão ao quadrado dessa heurística de previsão. As três heurísticas de previsão utilizadas foram prever por meio do preditor rígido, do preditor adaptativo e do preditor VAR. Resultados emergentes do modelo computacional mostraram que a heterogeneidade das expectativas é persistente ao

longo dos períodos da simulação, reproduzindo assim o fato estilizado de persistência de heterogeneidades das expectativas de inflação.

Já no capítulo 5 foi mostrado o modelo de formação de expectativas associado à Pesquisa Focus, sendo, nesse caso, a utilidade determinística dependente do incentivo gerado pelo possível ganho reputacional de compor o *ranking* Top 5. Assim, a utilidade determinística proposta passou a ser dada pelo negativo da soma do custo médio da estratégia de previsão com uma variável que mensura um possível ganho de posição no *ranking* de escolha dos Top 5. Assim, diferentemente do modelo apresentado no capítulo 4, o *payoff* de cada participante da pesquisa dependeu não só do preditor escolhido pelo agente, mas também das escolhas de preditores feitas pelos demais agentes. A introdução da Pesquisa Focus no processo de formação de expectativas implicou na ampliação do campo de escolha dos agentes e eles passaram a poder escolher prever por meio do preditor rígido, prever por meio do preditor adaptativo, prever por meio do preditor VAR, utilizar como estratégia de previsão copiar a mediana das expectativas dos agentes Top 5 e também podiam simplesmente não realizar previsões no período. A persistência da heterogeneidade das expectativas também foi encontrado como uma propriedade emergente do modelo em questão. No entanto, para o modelo considerado no capítulo 5, a dispersão das expectativas se tornaram menores, isto é, os agentes passaram a escolher a estratégia de previsão que apresentou maior acurácia com maior intensidade se comparado ao modelo do capítulo 4. Esse resultado é um indício de que o mecanismo de escolha do *ranking* Top 5 torna o processo de seleção das estratégias de previsão mais eficaz, ou seja, proporcionam uma maior racionalidade no processo de escolha dos mecanismos de previsão.

No capítulo 5 também foi feita a simulação para o caso em que se desconsidera o valor do custo médio dos preditores. O resultado mostrou que parece haver uma maior utilização das estratégias de previsão que antes possuíam maior custos. Por exemplo, a estratégia de prever por meio do preditor VAR, em média, apresentou melhor acurácia nas previsões, porém como o custo de utilizar esse preditor era o maior possível, quando a hierarquia de custos médios é desconsiderada, uma maior proporção de agentes passaram a utilizar esse preditor. Apontou-se como uma possível causa para esse comportamento o fato de que, em momentos de baixa volatilidade da inflação, o custo de obter e processar as informações pode não compensar o benefício de formar expectativas de maneira ótima.

Mostra-se ainda no capítulo 5 que algumas das propriedades agregadas das expectativas dos participantes da Pesquisa Focus podem ser geradas como propriedades emergentes do modelo computacional. Em particular, observou-se que, assim como nos dados empíricos, a diferença de desempenho do grupo Top 5 em relação ao agregado dos agentes tende a ser mais acentuada quando o desvio padrão das expectativas aumentam. O aumento do desvio padrão, por sua vez, pode ser um in-

dício de que está mais difícil prever a inflação. Assim, esse resultado leva a crer que, em momentos de maior dificuldade em prever a inflação, o diferencial de desempenho entre os agentes Top 5 e o agregado dos agentes tende a ser maior. Além disso, o erro médio de previsão do grupo Top 5 foi menor do que do agregado dos agentes. Portanto, tais resultados levam a crer que os agentes que possuíram melhor desempenho no passado continuam apresentando, em geral, melhor desempenho do presente. Por fim, foi encontrado também uma menor correlação entre a mediana das expectativas e o desvio padrão para o grupo Top 5 em relação ao agregado dos agentes, indicando que existe uma maior proximidade das previsões dentro do grupo Top 5 do modelo computacional.

Dado que a Pesquisa Focus também elabora *rankings* para previsões de médio e longo prazos, para trabalhos futuros, propõe-se explorar as formações de expectativas em ambos os referidos prazos, de modo a verificar possíveis mudanças na porcentagem de agentes que utilizam cada estratégia de previsão quando o horizonte de previsão é aumentado.

REFERÊNCIAS

- ADAM, Klaus. Experimental evidence on the persistence of output and inflation. **The Economic Journal**, Oxford University Press Oxford, UK, v. 117, n. 520, p. 603–636, 2007.
- ALMEIDA, Helberte João França; SILVEIRA, Jaylson Jair da. Formação de expectativas de inflação em um ambiente de racionalidade limitada: uma abordagem de escolha discreta. **Estudos Econômicos (São Paulo)**, SciELO Brasil, v. 47, n. 3, p. 465–486, 2017.
- ASSENZA, Tiziana *et al.* Individual expectations and aggregate macro behavior. Tinbergen Institute discussion paper 13-016/II, 2013.
- BANCO CENTRAL DO BRASIL. **Alterações na definição das datas de referência para os rankings Top 5**. 2019a. Disponível em: https://www.bcb.gov.br/content/controleinflacao/Documents/Expectativas_mercado/Focus/T20200116-alteracoes-na-Definicao-das-Datas-de-Referencia-Rankings-Top5.pdf.
- BANCO CENTRAL DO BRASIL. **Instituições Top 5 - Classificação Anual para as Categorias Curto e Médio Prazo e Consolidação da Metodologia**. 2019b. Disponível em: https://www.bcb.gov.br/content/controleinflacao/Documents/Expectativas_mercado/Focus/E20080211-Top5-Classificacao-Anual-para-as-Categorias-Curto-e-Medio-Prazo-e-Consolidacao-da-Metodologia.pdf.
- BANCO CENTRAL DO BRASIL. **Relatório de Inflação**. 2004. Disponível em: <https://www.bcb.gov.br/controleinflacao/faqexpectativa>.
- BANCO CENTRAL DO BRASIL. **Sistema Expectativas de Mercado - Perguntas Frequentes**. 2019c. Disponível em: <https://www.bcb.gov.br/controleinflacao/faqexpectativa>.
- BLANCHFLOWER, David G; MACCOILLE, Conall. **The formation of inflation expectations: an empirical analysis for the UK**. [S.l.], 2009.
- BOGDANSKI, Joel; TOMBINI, Alexandre A; WERLANG, Sergio R da C. Implementing inflation targeting in Brazil. **Werlang, Sergio R., Implementing Inflation Targeting in Brazil (July 2000)**. Banco Central do Brasil Working Paper, n. 1, 2000.
- BRANCH, William A. The theory of rationally heterogeneous expectations: evidence from survey data on inflation expectations. **The Economic Journal**, Oxford University Press Oxford, UK, v. 114, n. 497, p. 592–621, 2004.
- BROCK, William A; HOMMES, Cars H. A rational route to randomness. **Econometrica: Journal of the Econometric Society**, JSTOR, p. 1059–1095, 1997.

BURKE, Mary A; MANZ, Michael. Economic literacy and inflation expectations: evidence from a laboratory experiment. **Journal of Money, Credit and Banking**, Wiley Online Library, v. 46, n. 7, p. 1421–1456, 2014.

CAETANO, Sidney Martins; JÚNIOR, Geraldo Edmundo Silva. Inflationary expectatives: predicting, persistence, and disagreement. **Análise Econômica**, v. 30, n. 58, 2012.

CAPISTRÁN, Carlos; TIMMERMANN, Allan. Disagreement and biases in inflation expectations. **Journal of Money, Credit and Banking**, Wiley Online Library, v. 41, n. 2-3, p. 365–396, 2009.

CARROLL, Christopher D. Macroeconomic expectations of households and professional forecasters. **the Quarterly Journal of economics**, MIT Press, v. 118, n. 1, p. 269–298, 2003.

CARVALHO, Fabia A de; MINELLA, André *et al.* Market Forecasts in Brazil: performance and determinants. **Central Bank of Brazil Working Paper Series**, n. 185, 2009.

CARVALHO, Fabia A; MINELLA, André. Survey forecasts in Brazil: a prismatic assessment of epidemiology, performance, and determinants. **Journal of International Money and Finance**, Elsevier, v. 31, n. 6, p. 1371–1391, 2012.

CONLISK, John. Why bounded rationality? **Journal of economic literature**, JSTOR, v. 34, n. 2, p. 669–700, 1996.

HODRICK, Robert J; PRESCOTT, Edward C. Postwar US business cycles: an empirical investigation. **Journal of Money, credit, and Banking**, JSTOR, p. 1–16, 1997.

HOMMES, Cars. **Behavioral rationality and heterogeneous expectations in complex economic systems**. [S.l.]: Cambridge University Press, 2013.

HOMMES, Cars. Heterogeneous agent models in economics and finance. **Handbook of computational economics**, Elsevier, v. 2, p. 1109–1186, 2006.

LEMOS, Fernando Herrero. A discordância nas expectativas de inflação no Brasil: um estudo empirico, 2017.

MANKIW, N Gregory; REIS, Ricardo; WOLFERS, Justin. Disagreement about inflation expectations. **NBER macroeconomics annual**, MIT Press, v. 18, p. 209–248, 2003.

MARQUES, André Barbosa Coutinho; FACHADA, Pedro; CAVALCANTI, Diogo Cogo. Number 36 May 2003, 2003.

MEURER, Roberto; LIMA, Gilberto. **Heterogeneity in Monthly Inflation Expectations in Brazil: Evidence with Aggregate Data from the Focus Survey**. [S.l.], 2017.

PFAJFAR, Damjan; SANTORO, Emiliano. Heterogeneity, learning and information stickiness in inflation expectations. **Journal of Economic Behavior & Organization**, Elsevier, v. 75, n. 3, p. 426–444, 2010.

PFAJFAR, Damjan; ŽAKELJ, Blaž. Inflation expectations and monetary policy design: Evidence from the laboratory. **Macroeconomic Dynamics**, Cambridge University Press, v. 22, n. 4, p. 1035–1075, 2018.

PRADA, Marcela. **Premiação top 5: estudo de um caso de torneio no Brasil**. 2007. Tese (Doutorado).

TRAIN, Kenneth E. **Discrete choice methods with simulation**. [S.l.]: Cambridge university press, 2009.

WEBER, Anke. Heterogeneous expectations, learning and European inflation dynamics. Bundesbank Series 1 Discussion Paper, 2007.